

---

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# DIPLOMSKI RAD

**Petar Gregurić**

Zagreb, 2018.

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

**DIPLOMSKI RAD**

Mentor: prof.dr.sc. Nedeljko Štefanić, dipl.ing

Student: Petar Gregurić

Zagreb, 2018.



Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu. Najviše se zahvaljujem svojem mentoru, profesoru Nedeljku Štefaniću koji me je uveo u zanimljiv svijet Industrije 4.0 i stajao na raspolaganju za sva pitanja.

Petar Gregurić



SVEUČILIŠTE U ZAGREBU  
**FAKULTET STROJARSTVA I BRODOGRADNJE**



Središnje povjerenstvo za završne i diplomske ispite  
Povjerenstvo za diplomske radove studija strojarstva za smjerove:  
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment,  
inženjerstvo materijala te mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum:	Prilog:
Klasa:	
Ur. broj:	

## DIPLOMSKI ZADATAK

Student: **PETAR GREGURIĆ** Mat. br.: **0035195394**

Naslov rada na hrvatskom jeziku: **Vitka i digitalna transformacija proizvodnih procesa**

Naslov rada na engleskom jeziku: **Lean and digital transformation of manufacturing processes**

Opis zadatka:

Pojava Industrije 4.0 prije više od pet godina na sajmu u Hannoveru, prepoznata je kao mogućnost razvoja novih proizvodnih i poslovnih modela koja će pojedinim industrijama i poduzećima osigurati snažan napredak kroz unapređenje procesa i proizvoda. Koncept Industrije 4.0 povezan je s pojmovima poput kibernetско-fizički sustavi, internet stvari, internet usluga, računarstvo u oblacima, komunikacija između ljudi i strojeva (ali i strojeva međusobno), umjetna inteligencija, proširena stvarnost te mnogim drugima. U Hrvatskoj je na našem fakultetu razvijena Dualna strategija transformacije poduzeća koja povezuje alate vitkog menadžmenta i digitalne tehnologije.

U radu je potrebno:

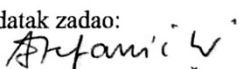
- a) Detaljno opisati koncept industrije 4.0 te njene najvažnije tehnologije.
- b) Razraditi sustav povezivanja vitkog menadžmenta i digitalnih tehnologija.
- c) Na primjeru proizvoljnog proizvodnog poduzeća i odabranog proizvodnog procesa primijeniti sustav vitke i digitalne transformacije.
- d) Kvantificirati dobivene rezultate.
- e) Sistematizirati raspoložive računalne programe za vitku i digitalnu transformaciju te odabrati jedan od njih i primijeniti ga.

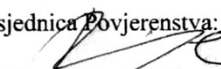
U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:  
03. svibnja 2018.

Rok predaje rada:  
05. srpnja 2018.

Predviđeni datum obrane:  
11. srpnja 2018.  
12. srpnja 2018.  
13. srpnja 2018.

Zadatak zadao:  
  
prof. dr. sc. Nedeljko Štefanić

Predsjednica Povjerenstva:  
  
prof. dr. sc. Biserka Runje

# SADRŽAJ

SADRŽAJ .....	5
POPIS SLIKA .....	7
SAŽETAK .....	9
SUMMARY .....	10
1. UVOD .....	11
2. Povijest velikih transformacija .....	12
2.1 Prva industrijska revolucija .....	12
2.2 Druga industrijska revolucija .....	14
2.3 Treća i četvrta industrijska revolucija .....	14
3. Industrija 4.0 .....	16
3.1 Vertikalna i horizontalna integracija .....	17
3.2 Prednosti i nedostaci .....	18
3.3 Izazovi implementacije Industrije 4.0 .....	19
3.4 Četvrta industrijska revolucija - Što znači? .....	20
3.5 Glavni trendovi Industrije 4.0 .....	20
3.6 Industrija 4.0 u Hrvatskoj .....	21
4. Tehnologije Industrije 4.0 .....	23
4.1 Big Data .....	23
4.2 Autonomni roboti .....	24
4.3 Simulacije .....	24
4.4 IoT .....	24
4.5 Kibernetička sigurnost .....	26
4.6 Internet u oblacima .....	28
4.7 Aditivna proizvodnja .....	29
4.7.1 Aditivna proizvodnja - materijali .....	31
4.7.2 Kako izgleda postupak aditivne proizvodnje? [38] .....	34
4.8 VR i AR .....	37
4.8.1 Primjena VR i AR .....	38
4.9 Umjetna inteligencija .....	42
4.9.1 AI u primjeni .....	42
4.9.2 Primjer u proizvodnji [41] .....	44
5. Ekosustavi digitalizacije .....	46
6. Povezivanje leana i digitalizacije kroz dualnu strategiju .....	51
6.1 Vitka transformacija .....	52
6.1.1 Što je lean? .....	52
6.1.2 Stanje u svijetu .....	55
6.1.3 Primjer potencijala leana .....	56
6.2 5 koraka vitke transformacije poduzeća .....	57
6.3 Foot in the door .....	57
6.4 Lean simulacije .....	58
6.4.1 Toranj od spaghetti .....	58
Kako igrati? .....	58

6.4.2 Igra kovanicama.....	61
Kako igrati? [9] .....	61
6.4.3 Albatross .....	64
6.5. Kaizen .....	69
6.5.1 Primjena Kaizena [6] .....	69
6.6 5S7I .....	
6.6 VSM.....	72
6.7 Standardizacija.....	73
6.8 Kvaliteta .....	74
7. 7 koraka digitalne transformacije poduzeća .....	76
8. Primjena sustava vitke i digitalne transformacije u Feroimpexu.....	77
8.1. O poduzeću [59].....	77
8.2 Proizvodni pogon.....	79
8.3 Proizvodi .....	79
5.3 Alatnica .....	80
8.4 Odabir procesa .....	80
8.5 Problem kontrolnih urica .....	80
Kaizen radionica .....	82
Digitalizacija tokarilice .....	84
5. Zaključak.....	92
LITERATURA .....	93

## POPIS SLIKA

Slika 1. Prva industrijska revolucija .....	13
Slika 2. 3D printer .....	15
Slika 3. Industrija 4.0 [13] .....	16
Slika 4. Vertikalna i horizontalna integracija .....	18
Slika 5. DESI [19] .....	21
Slika 6. IoT .....	25
Slika 7. Pametno upravljanje logistikom .....	26
Slika 8. Kibernetička sigurnost .....	28
Slika 9. Cloud .....	28
Slika 10. Dropbox .....	29
Slika 11. Okvir bicikla .....	33
Slika 12. Adidasova tenisica [35] .....	34
Slika 13. CAD modeliranje [39] .....	35
Slika 14. Izradak s postoljem [38] .....	36
Slika 15. Vađenje izratka [38] .....	36
Slika 16. Držač kartica [38] .....	37
Slika 17. AR [15] .....	39
Slika 18. AR bez označivača [15] .....	40
Slika 19. Vizualizirajuća poboljšana stvarnost .....	41
Slika 20. Projicirana poboljšana stvarnost .....	41
Slika 21. KIVA inteligentni robot [43] .....	43
Slika 22. Netflix preporuke [44] .....	44
Slika 23. Pametna tvornica [45] .....	45
Slika 24. Pametno upravljanje skladištem [46] .....	46
Slika 25. Airbnb [47] .....	47
Slika 26. Uber [48] .....	47
Slika 27. GuestReady [50] .....	48
Slika 28. Amazon HQ [51] .....	50
Slika 29. Primjenjivost dualne transformacije .....	52
Slika 30. Lean .....	53
Slika 31. Primjer iz igre .....	59
Slika 32. Belbinove uloge .....	60
Slika 33. Usporedbe vremena .....	63
Slika 34. Radno mjesto prije i poslije provedbe 5S [54] .....	72
Slika 35. Primjer VSM mape [56] .....	73
Slika 36. Six sigma implementacija [58] .....	75
Slika 37. Umrežavanje internet stvari [57] .....	76
Slika 38. 7 koraka digitalizacije [57] .....	76
Slika 39. FAT .....	77
Slika 40. Proizvodna hala .....	78
Slika 41. Alatnica .....	79
Slika 42. Proizvodi .....	79
Slika 43. Kontrolne urice .....	81
Slika 44. Puma 2600 [66] .....	84
Slika 46. FTDI [71] .....	86
Slika 47. Arduino Pro mini shema [72] .....	86

Slika 48. REED switch [63].....	87
Slika 49. Limit switch [64] .....	87

## **SAŽETAK**

Poduzeća koja žele ostati konkurentna na globalnom tržištu moraju proći kroz vitku i digitalnu transformaciju kako bi postale dio Industrije 4.0. Nema smisla digitalizirati procese koji su zastarjeli te nisu efikasni. Upravo zato se kreće s leanom. Lean transformacijom podiže se produktivnost i efikasnost procesa koji se potom digitaliziraju. Rezultat je produktivnije i kompetitivnije poduzeće.

Termin „Industrija 4.0“ predstavlja organizaciju čiji tehnološki bazirani proizvodni procesi i uređaji međusobno autonomno komuniciraju tvoreći virtualna računalna okruženja. Naglasak je na inovacijama koje se koriste upotrebom najnovijih tehnologija čime se povećava produktivnost, konkurentnost te generalno tržišna prednost pred ostalim industrijama. Pored navedenog Industrija 4.0 podrazumijeva promjene u standardizaciji, uvođenje novih poslovnih modela, sigurnosti informacija, dostupnosti produkata, istraživanja, dostupnosti adekvatne radne snage, radnih procesa te promjena samih organizacija. Hrvatska se na ljestici Industrija nalazi na 2.5. Dobar pokazatelj razine digitalizacije društva je DESI indeks po kojem je RH na 22.mjestu u Europskoj Uniji. Mjesta za napredak ima.

Dualna transformacija recept je za povezivanje vitke i digitalne transformacije koji se sastoji od 5 lean alata i 7 alata digitalizacije. U ovom radu, prikazana je primjena dualne transformacija u tvrtci Feroimpex - automobilska tehnika.

## **SUMMARY**

Companies wishing to remain competitive on a global market must go through a lean and digital transformation to enter Industry 4.0. There is no point in digitally transforming processes that are outdated and are not efficient. That's exactly why the process needs to be started with lean. Lean transformation first raises the productivity and efficiency of a process and then it can be digitized. The result is more productive and competitive enterprise.

The term "Industry 4.0" is a term for an organization whose technology-based manufacturing processes and devices interact autonomously with each other by creating virtual computing environments. The emphasis is on innovations that are utilized using the latest technologies, thus increasing productivity, competitiveness and overall market advantage over other industries. In addition, this implies changes in standardization, the introduction of new business models, cybernetic security, product availability, research, availability of adequate workforce, work processes, and changes to organizations themselves. Croatia is currently at Industry 2.5 level. A good indicator of the level of digitization of society is the DESI index by which the Republic of Croatia is the 22nd in the European Union. The potential for progress is present.

The dual transformation is a blueprint for connecting lean and digital transformations, consisting of 5 lean tools and 7 digitization tools. In this paper, the dual transformation was implemented in the company Feroimpex - AT.



## 1. UVOD

Dan danas vode se bitke između konkurentnih tvrtki. One se ne vode više na ulicama, ne vode se na poljima, već se vode u izvršnim odborima korporacija, kao i u proizvodnim pogonima.

Svaki napredak do sada bio je popraćen inovacijama i promjenama. Oni koji su se najbrže i najbolje prilagodili izašli su na vrhu. Tako je bilo u vrijeme svih većih društvenih promjena. Krenuvši od industrijskih revolucija, pa dolazeći do dana današnjeg, gdje je sljedeći trend odnosno bolje rečeno nužnost kroz koju će tvrtke morati proći digitalna transformacija.

No nekada je teško pojedinca uvjeriti u nužnost promjene. Ljudi su po prirodi stvari inertni, vole status quo. Poznata je rečenica “ne talasaj”. Nemoj ići u nepoznato. Pusti nešto da funkcionira dok god funkcionira. Naravno da je takav stav pogrešan.

Upravo zato osmišljene su lean simulacija odnosno igre. Kako bi na vrlo banalan, jednostavan, a opet smislen način demonstrirale sudionicima prednosti implementacije novih metoda. Nužnosti promjene. Nužnosti kontinuiranog unaprjeđenja.

Lean simulacije mogu se protumačiti kao modificirana “foot in the door” tehnika, koja kroz jednostavnu igru prikaže pogodnosti i benefite te je nakon toga mnogo jednostavnije menadžment, ali i radnike uvući u kompletni proces promjene jer će shvatiti što će time postići. Veću produktivnost, efikasnost i manji gubitak vremena na nepotrebne sitnice.

Hrvatska industrija nalazi se između Industrije 2.0 i 3.0, dok ostatak svijeta teži i ulazi u četvrtu industrijsku revoluciju. Poduzeća koja se ne transformiraju u iduće 3 godine vrlo teško će ostati konkurentna. Upravo zato razvijena je dualna strategija koja obuhvaća vitku i digitalnu transformaciju poduzeća. Dualnu strategiju primijenio sam na procesu u Feroimpex - Automobilskoj tehnici te su rezultati pozitivni. Digitalizacija procesa i proizvodnje dovesti će, ne samo do rasta produktivnosti i pada troškova, već i do novih prihoda jer se tako poduzeća otvaraju globalnom tržištu.

## 2. Povijest velikih transformacija

Svijet je do sada prošao kroz 3 velike revolucije, zvane industrijskim revolucijama. Svaka je donijela brojne promjene, oni najbolji, koji su se najbrže adaptirali, od njih su profitirali, no dio njih, nedovoljno adaptivan, nedovoljno prilagodljiv, nedovoljno agilan propao je. Svaka revolucija donosi nove izazove.

### 2.1 Prva industrijska revolucija


Prva industrijska revolucija označava promjenu s ručne na industrijsku proizvodnju. Dolazi do potpune transformacije svih životnih aspekata jer su se do tada ljudi oslanjali uglavnom na vlastitu snagu i snagu domaćih životinja, a sada su ih počeli zamjenjivati strojevi. Ovaj proces se javio u Engleskoj u osamnaestom stoljeću (od 1760. do 1830. industrijska revolucija je i bila vezana samo za Veliku Britaniju, a poslije se počela širiti po ostatku Europe i svijeta) i njezine glavne značajke se mogu podijeliti na tehnološke, socioekonomske i kulturne.

Najvažniji izum ovog perioda, koji je i svojevrsni katalizator za ostala dostignuća, bio je parni stroj koji je patentirao i doradio James Watt 1763. godine i koji je omogućio veću industrijsku proizvodnju, uz manji utrošak energije. Osim napretka u proizvodnji, ovo je bilo i vrijeme napretka prometa i brojnih znanosti.

Tehnološke promjene su uključivale:

- korištenje novih materijala, uglavnom željeza i čelika,
- upotrebu novih izvora energije, goriva i pogonske sile poput ugljena, koji je postao glavni faktor uspješne industrijalizacije jer je korišten za proizvodnju pare o kojoj je industrija ovisila,
- izume novih strojeva, poput stroja za predenje s osam vretena (eng. spinningjenny) i mehaničkog tkalačkog stana koji su unaprijedili tehniku proizvodnje tekstila uz
- smanjenju potrošnju ljudske energije,
- tvornice kao nove radne organizacije koje su omogućile podjelu i specijalizaciju za specifične poslove,
- važna dostignuća u području komunikacije i prijevoza
- sve veća sinergija znanosti i industrije

Ove tehnološke promjene omogućile su iskorištavanje prirodnih resursa te povećanje kapaciteta proizvodnje robe. [5]



**Slika 1. Prva industrijska revolucija**

## 2.2 Druga industrijska revolucija

S obzirom na dubinu i značaj promjena koje su se dogodile, početak upotrebe električne energije i nafte ujedno se smatra i početkom druge industrijske revolucije, perioda koji je trajao od 1870. do 1914. godine.

Počeli su se koristiti mnogi prirodni i sintetički resursi, otkrivene su nove legure i materijali poput plastike, kao i novi izvori energije. Kombinirano s prethodnim, došlo je do proizvodnje nekih novih strojeva, kao i do povećanja stupnja automatizacije tvornica.

Druga industrijska revolucija obilježena je mnoštvom novih izuma, kao što su:

- telefon
- radio, telegraf
- dizelski i benzinski motor,
- električna žarulja
- motor s unutarnjim izgaranjem,
- x-zrake

Vlasništvo sredstava za proizvodnju također je evoluiralo. Pojedincima je postalo moguće ući u vlasništvo tvrtke kroz kupovinu dionica. U prvoj polovici 20. stoljeća došlo je i do promjena u političkom pogledu na gospodarstvo. Umjesto laissez-faire ideja koje su dominirale klasičnom industrijskom revolucijom, vlade su počele promovirati određeno socijalno-gospodarske mjere. [5]

## 2.3 Treća i četvrta industrijska revolucija


Treća industrijska revolucija ili digitalna revolucija predstavlja promjenu iz analogne u digitalnu tehnologiju koja se počela razvijati od osamdesetih godina dvadesetog stoljeća pa do danas. Dok je naglasak druge industrijske revolucije bio na masovnoj proizvodnji, danas je trend i cilj svake tvrtke koja želi opstati prilagoditi usluge ili proizvod individualno kupcu.

Poznata je izreka koju je Ford davnih dana rekao: “Kupci mogu odabrati bilo koju boju dok god je crna”. Male serije bile su neisplative, previše ulaganja u izmjene procesa bile su potrebne, te dodatna zarada nije opravdala trošak.

Danas svaki kupac ima svoje preferencije. Tvornice budućnosti biti će orijentirane masovnom prilagođavanju proizvoda.

Brojne nove tehnologije su već danas dostupne: inteligentni softveri, novi materijali, pametni roboti, 3D printanje, virtualna stvarnost, blockchain..

“Stari” način proizvodnje uključivao je konstruirane dijelova i njihovo montiranje, pričvršćivanje ili zavarivanje zajedno. Sada se proizvod može dizajnirati na računalu i "isprintati" na 3D printeru. 3D printer može raditi bez nadzora i može proizvesti mnoge stvari koje su previše složene za tradicionalni način proizvodnje. S vremenom, vjerojatno ćemo moći isprintati i vlastiti brod.



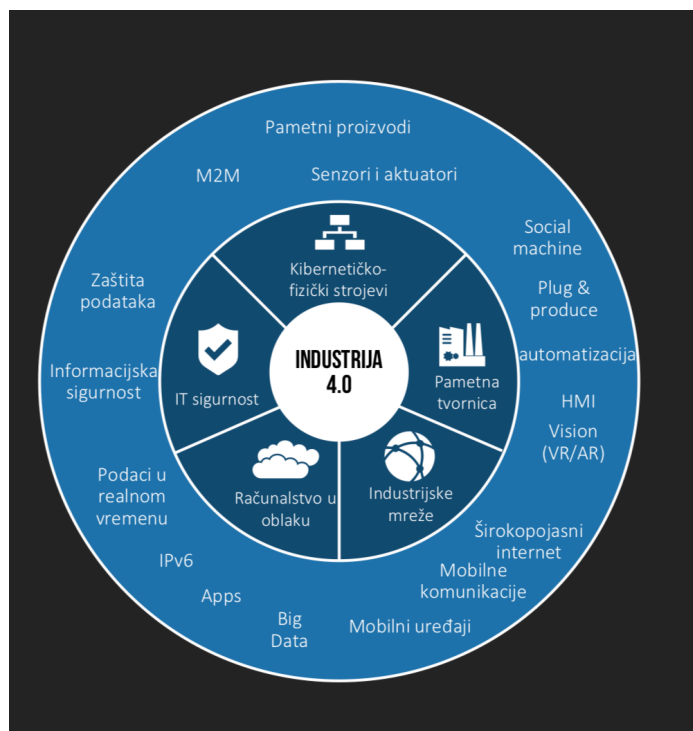
**Slika 2. 3D printer**

### 3. Industrija 4.0

Glavna ideja Industrije 4.0 je povezivanje svih komponenti jednog sustava u zajednički hub koji međusobno može bežično komunicirati. Pojam Industrija 4.0 ušao je u redoviti vokabular, čak i kada mu tamo nije mjesto. Počeo se koristiti u svim prilikama. Stvar je u tome što se radi o veoma kompleksnom pojmu koji je na prvu teško za shvatiti. Predstavlja pojam koji kao cluster obuhvaća sinergiju kibernetičko-fizičkih sustava, pametnih strojeva s mogućnošću neovisne razmjene podataka, pametnih tvornica, industrijske mreže, računarstva u oblaku, IT sigurnosti te sveukupnu kontrolu i optimizaciju proizvodnje u realnom vremenu.

Termin „Industrija 4.0“ predstavlja organizaciju i, unutar iste, tehnološki bazirane proizvodne procese i uređaje koji međusobno autonomno komuniciraju tvoreći virtualna računalna okruženja. Naglasak je na inovacijama koje se koriste upotrebom najnovijih tehnologija čime se povećava produktivnost, konkurentnost, generalno tržišna prednost pred ostalim industrijama. Pored navedenog Industrija 4.0 podrazumijeva promjene u standardizaciji, novih poslovnih modela, sigurnosti informacija, dostupnosti produkata, istraživanja, dostupnosti adekvatne radne snage, radnih procesa te promjena samih organizacija.

Industrija 4.0 se može definirati i kao pristup koji uključuje umrežene proizvodne sustave koji pristupaju izmjenama u proizvodnom procesu kroz alternativne strategije. [13]



Slika 3. Industrija 4.0 [13]

Nadalje, „Industrija 4.0“ stvara ono što se naziva "pametna tvornica". Unutar modularno strukturiranih pametnih tvornica, kibernetско-fizički sustavi nadziru fizičke procese, stvaraju virtualnu kopiju fizičkog svijeta i čine decentralizirane odluke. Preko interneta stvari (IOT), kibernetско-fizički sustavi komuniciraju i surađuju jedni s drugima i s ljudima u stvarnom vremenu, putem interneta usluga, i to unutarnjih i među-organizacijskih usluga, a koriste se od strane sudionika u lancu vrijednosti. Upravo zbog svega navedenog se „Industrija 4.0“ često naziva i „Četvrta industrijska revolucija“, tj. pravilnije bi bilo reći da je ona pokretač i strukturno temeljna komponenta navedene revolucije.

Industrija 4.0 na gospodarstvo utječe na razne načine. Treba razdvojiti utjecaj na tvrtke i radnik. Lokalizirane i identificirane proizvodne serije omogućuju više saznanja o proizvodnom procesu, povezanost unutar organizacije raste, kao i prilagodljivost i mogućnost optimizacije proizvodnog procesa putem kontinuiranog prikupljanja vanjskih i unutarnjih podataka te dolazi do individualizacija proizvodnje prema zahtjevima kupca. S druge strane, radnicima prolaze dodatne edukacije te postaju konkurentniji na tržištu rada, više ih se uključuje u procese odlučivanja, dolazi do većeg nivoa zadovoljstva radnika zbog toga što teške, jednolične, opasne poslove preuzimaju roboti, a radnici se sele na nove pozicije. Mijenjaju se organizacijske strukture poduzeća u smjeru decentralizacije odnosno veće autonomije zaposlenika. [13]

### **3.1 Vertikalna i horizontalna integracija**

Prilikom digitalne transformacije dolazi do vertikalne i horizontalne integracije unutar poduzeća. Što to znači?

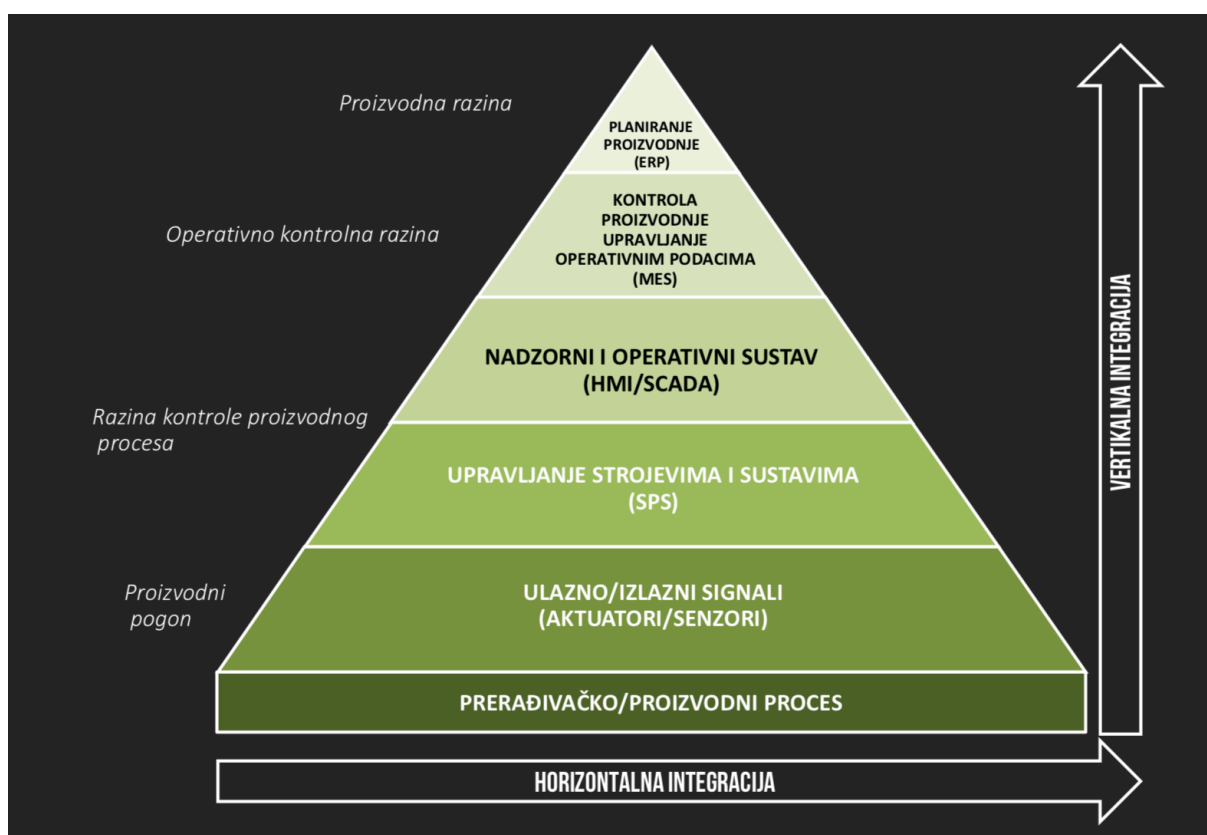
Vertikalna integracija predstavlja umrežavanje proizvodnih sustava kroz alternativne strategije. Regulatorni okvir vertikalne integracije je “pametna tvornica”. U budućnosti proizvodni blokovi neće više biti statični i predodređeni. Definirat će se IT konfiguracijska pravila iz kojih će se kreirati specifična proizvodna struktura. Sve u svemu, dolazi do mrežne povezanosti unutar organizacijske strukture poduzeća, od najnižih operativnih nivoa, do najvišeg menadžmenta. [13]

Horizontalna integracija jest naziv za optimiziranje toka sirovine i informacija kroz lanac vrijednosti, od dobavljača do isporuke kupcu. U industriji 4.0 međusobno umreženi IT sustavi, potpomognuti umjetnom inteligencijom, pratit će potrebe za sirovinama u svim koracima lanca

vrijednosti. Temeljem tih informacija, moći će se promptno reagirati na izmjene u potrebama te shodno tome kreirati specifične planove proizvodnje. [13]

Pri horizontalnoj integraciji dolazi do:

- umreženosti proizvodnih lokacija
- razmjene informacija kroz cijeli lanac vrijednosti
- uključenosti kupca u proizvodni proces
- inteligentne komunikacije u nabavi, proizvodnji i logistici [13]



Slika 4. Vertikalna i horizontalna integracija

### 3.2 Prednosti i nedostatci

Uvijek u svakoj inovaciji odnosno promjeni postoje prednosti i mane. Naravno da je prednosti značajno više od mana, no na subjektima je, koji se spremaju proći kroz digitalnu transformaciju, da procijene što im odgovara.



Kada se ranije navedene prednosti sumiraju postaje jasno da prelaskom na Industriju 4.0 dolazi do višeg stupnja prilagodljive proizvodnje, smanjenog pritiska na radnike, povećane konkurentnosti i stvaranja veće vrijednosti, usmjerenosti na produktivnost i efikasnu upotrebu resursa te do orijentacije na individualne zahtjeve kupaca.

S druge strane, dolazi do određenih izazova prilikom zaštite podataka te olakšane manipulacije proizvodnim sustavima. Nužno je dodatno investirati u opremu za zaposlenike te u njihovu edukaciju, gdje treba uzeti u obzir i potencijalni oportunitetni trošak prilikom educiranja. Održavanje na infrastrukturi košta te u ruralnim područjima širokopojasna mreža slabije funkcionira što može dovesti do problema kada su svi procesi digitalizirani te ovise o međusobnoj, kontinuiranoj povezanosti. [13]

### 3.3 Izazovi implementacije Industrije 4.0

Profesionalne udruge za istraživanje međunarodnih tržišta BITKOM, VDMA i ZVEI provele su 2013. godine istraživanje na 278 kompanija s temom Industrije 4.0. Postavljeno pitanje je glasilo da označe pojmove koje smatraju temeljima za implementaciju. Kod većine to je standardizacija procesa u svim segmentima sustava, dok slijede organizacija posla koja vodi većoj odgovornosti i razvoju zaposlenika te dostupnost proizvoda. [13]

Novi poslovni i organizacijski modeli su neizbježni. Sigurnost i zaštita informacija jedan od glavnih izazova digitalizacije. U anketi je još jednom dokazano da bez stručnih kadrova nezamisliv je ikakav tehnološki i poslovni iskorak, a istraživanje i razvoj, odnosno inovacije jedan su od glavnih faktora Industrije 4.0 koji se propagira u svim segmentima organizacije.

Standardizacija	52,8%
Organizacija procesa i rada	46,4%
Dostupnost proizvoda	35,3%
Novi poslovni modeli	30,6%
IT sigurnost	28,1%
Dostupnost kvalificiranih stručnjaka	25,2%
Istraživanje i razvoj	23%
Obrazovanje i kontinuirani razvoj	15,10%
Regulatorni i zakonski okviri	10,8%

### 3.4 Četvrta industrijska revolucija - Što znači?

Vrlo često miješaju se pojmovi četvrta industrijska revolucija i Industrija 4.0. Na njih se ne bi trebalo gledati kao na sinonime, već više kao na komplementarne pojmove. Industrija 4.0 samo je dio kompletne revolucije. Industriju 4.0 već je ranije pobliže objašnjena, no što je četvrta industrijska revolucija?

Sinergija tehnologija koje brišu poznate granice između fizičke, digitalne i biološke dimenzije. Karakterizirana je značajnim tehnološkim inovacijama u raznim sferama, kao što su robotika, umjetna inteligencija, blockchain, nanotehnologija, kvantna računala, biotehnologija, 3D printanje, IoT, autonomna vozila i još mnogo toga. Bazirana je na poznatom pojmu digitalne transformacija. U svojoj knjizi "The fourth industrial revolution", profesor Klaus Schwab, osnivač Svjetskog ekonomskog foruma, opisuje četvrtu industrijsku revoluciju kao fundamentalno drugačiju od prethodne tri koje su bile bazirane primarno na tehnološkim napredcima, dok četvrta može drastično promijeniti pružajući poslovne prilike prethodno nezamislive. Pojam "4. industrijska revolucija" prvi puta spomenut je 2016. godine upravo na Svjetskom ekonomskom forumu u Davosu. [23]

Industrija 4.0 naziv je za skup tehnologija kojima stvaramo sustave odnosno poduzeća budućnosti, dok četvrta industrijska revolucija predstavlja konvergenciju odnosno ujedinjenje ljudi i tehnologije koja će zasigurno dovesti do mnogih etičkih rasprava.

### 3.5 Glavni trendovi Industrije 4.0


Postoji više interpretacija koji su glavni trendovi Industrije 4.0. No prema službenoj studiji Odbora za industriju, istraživanje i energiju Europske komisije iz 2016. godine postoji šest glavnih trendova[24]:

- interoperabilnost - kibernetско-fizikalni sustavi omogućavaju međusobno umrežavanje
- virtualizacija - stvaranje virtualne kopije pametne tvornice te simulacije rada
- decentralizacija - spuštanje centara donošenja odluka na niže nivoe te omogućavanje autonomne, lokalne proizvodnje
- analiza u stvarnom vremenu - sposobnost praćenja događaja u stvarnom vremenu, analiziranju i snimanju istih
- orijentiranost na usluge

- modularnost - fleksibilnost pametnih tvornica kako bi dijelovi sustava lako i brzo bili zamjenjivi

### 3. 6 Industrija 4.0 u Hrvatskoj

Ako govorimo o Industriji 4.0 kao novom globalnom cilju, hrvatska se industrija u prosjeku trenutno nalazi na razini Industrije 2.5.[21] Dobar parametar za mjeriti razinu digitalizacije jest DESI. DESI indeks je složeni pokazatelj gospodarske i društvene digitalizacije, koji Europskoj komisiji omogućava procjene razvoja država članica u području digitalne konkurentnosti koji pridonosi analitičkoj osnovi.



Slika 5. DESI [19]

DESI odnosno digitalni ekonomski index je mješavina indeksa koji sumiraju relevantne indikatore europske digitalne konkurentnosti i performansi te prati njihov napredak. [19] Sintetiziran je od 5 parametara. Prvi je povezanost koja mjeri kvalitetu mrežne infrastrukture. Računa se kao težinski prosjek fiksnog interneta, mobilnog, brzine i cijene. Drugi, označen crvenom bojom na grafu jest ljudski kapital koji mjeri potencijal znanja da se iskoriste prilike pružene digitalizacijom društva. Treći, “korištenje interneta” kvantificira koliko građana koristi usluge na internetu. Integracija digitalnih tehnologija mjeri razinu digitalizacije privatnog sektora. Digitalnom transformacijom poduzeća mogu povećati produktivnost, smanjiti troškove te ostvariti kvalitetniji odnos s kupcima. Razina digitalizacije javnog sektora, kao zadnja kategorija, predstavlja razinu digitalizacije države.

U kakvom stanju trenutno je Hrvatska na DESI ljestvici?

DESI za Hrvatsku iznosi 46.7, čime se smjestila na 22. mjesto. U usporedbi s prethodnom godinom, Hrvatska je napredovala za jedno mjesto. U kategoriji “povezivost” nalazi se na niskom 27. mjestu što u praksi znači da Hrvatska ima jedan od najlošijih internet infrastruktura u EU. Očekuje se da će Hrvatska poboljšanjem povezivosti, a koja se ostvaruje Nacionalnim programom razvoja širokopojasne agregacijske infrastrukture i Okvirnim nacionalnim programom za razvoj infrastrukture širokopojasnog pristupa u područjima u kojima ne postoji dostatan komercijalni interes za ulaganja, pridonijeti većoj potrošnji i potaknuti ulaganja u brzu internetsku infrastrukturu te utjecati na smanjenje cijene fiksnog širokopojasnog pristupa za krajnje korisnike. [20]

Postoje 4 razine kompleksnosti proizvoda: niska, srednja, visoka i vrlo visoka. U Hrvatskoj gotovo da nema proizvoda iz 4. skupine. Hrvatska industrija generira 20% proizvoda koji su visoko kompleksni, a 80% spada u kategoriju niske kompleksnosti. [22] Vrlo je teško ostati konkurentan u sferi nisko kompleksnih proizvoda, čiju proizvodnju većina zapadnih poduzeća seli na istok. Kod nisko kompleksnih proizvoda, koji ne zahtijeva stručna znanja najznačajniji parametar u proizvodnji jest radna snaga, a Hrvatska u tom aspektu nikako ne može, niti bi trebala pokušavati konkurirati zemljama istoka. Cilj je povećati udio kompleksnih i visoko-kompleksnih proizvoda.

## 4. Tehnologije Industrije 4.0

Glavne tehnologije Industrije 4.0 nisu striktno određene. Boston Consulting Group u svojem istraživanju “Embracing Industry 4.0—and Rediscovering Growth” definirala je 9 vodećih tehnologija Industrije 4.0 [25]:

- Big data analize i predikcije
- autonomni roboti
- simulacije i umjetna inteligencija
- horizontalna i vertikalna integracija
- IoT - internet stvari
- kibernetička sigurnost
- internet u oblacima
- aditivna proizvodnja
- VR i AR

### 4.1 Big Data

U kontekstu Industrije 4.0 predstavlja skupljanje, kategoriziranje i analiziranje podataka prikupljenih u cjelokupnom lancu vrijednosti, od nabave preko proizvodnje do isporuke, koristiti se za donošenje odluka i optimizacije u stvarnom vremenu. Nadalje, big data analitika koristi se u prediktivnoj proizvodnji gdje su procjene da će se poboljšanja u efikasnosti i produktivnosti mjeriti u milijardama dolara u idućih 5 godina. Neki zagovaratelji idu tako daleko da čak definiraju četvrtu industrijsku revoluciju kao spoj umjetne inteligencije i big data analitike. [26]

Jedna tvrtka u Čileu primjerice koristi big data predikcije i strojno učenje za procjenu vjerojatnosti kojom će njihov klijent vratiti svoj dug. Samo ako pogledamo unatrag 20 godina, koliko je vremena odnosno radnih sati potrošeno za računanje kreditnih sposobnosti klijenata? Koliko ljudi je bilo zaposleno da radi na tome? Koliko je trajala procjena za jednu osobu i koliko je točna bila? Već danas, uz pomoć strojnog učenja i big data predikcija moguće je unijet nekolicinu parametara i gotovo trenutačno dobiti procjenu kreditnih sposobnosti. [26]

## 4.2 Autonomni roboti

Cijena nove tehnologije svakodnevno opada. Noviteti uvijek koštaju, no što više korisnika ima to je i cijena pristupačnija. Sjetimo se samo LCD televizije. Prije 10 godina najjeftiniji primjerak koštao je 20 tisuća kuna. Danas ih se može nabaviti već za 1500 kn.

Identična stvar dogodit će se, odnosno već se i događa, s industrijom robota. Roboti budućnosti bit će bolji, funkcionalniji, ali i jeftiniji nego danas. Zamijenit će ljude na opasnim i monotonim pozicijama za koje će sat ljudskog rada postati preskup. S vremenom, roboti će postajati autonomniji i pametniji te će komunicirati jedan s drugim i učiti od ljudi. [25]

## 4.3 Simulacije

Umjetna inteligencija koristi se u svrhe simuliranja procesa i predikcije. Teško je povući jasnu granicu između big data, strojnog učenja i umjetne inteligencije pošto se radi o pojmovima koji se zajedno isprepleću. Simulacije su zapravo procesi oponašanja stvarnog stanja. Mogu se primjenjivati u cijelom lancu vrijednosti za jeftiniji, brži i efikasniju demonstraciju rada i promjena koje želimo isprobati. Puno je jednostavnije kreirati matematički model te promijeniti jedan parametar i nakon toga sagledati rezultate, nego mijenjati taj parametar u pogonu te potom mjeriti rezultate na terenu.

## 4.4 IoT

“Internet of things” ili u prijevodu “Internet stvari” predstavlja bit Industrije 4.0. Umrežavanje svih hardvera te njihovo spajanje na internet. Industrija Internet stvari raste velikom stopom te prema nedavnoj Gartnerovoj analizi 15 posto kompanija već koristi IoT u svom poslovanju, najčešće logistici.

Kibernetičko-fizički sustavi funkcioniraju vrlo slično kao Internet stvari. Opremljeni su senzorima, softverima i svim ostalim elementima koji su dio Interneta stvari. Kibernetičko-fizički sustavi, baš kao i Internet stvari, bazirani su na međusobnom povezivanju. Internet stvari sastoje se od centralnog objekta s ugrađenim tehnologijama koje im omogućuju da primaju podatke, prikupljaju, obrađuju te ih šalju dalje za određenu svrhu. Ovisno o objektu i cilju koji želimo postići, to može biti snimanje podataka o kretanju, lokaciji, prisutnosti plinova u prostoriji, temperaturi, stanju uređaja.. Broj parametara koje želimo obrađivati je gotovo neograničen. No ti podaci, ulazne vrijednosti, sami su početak. Stvarna vrijednost Internet stvari započinje u sljedećem koraku, prilikom analize. [29]

Ukratko ću objasniti važnost IoT u proizvodnoj industriji. No prije svega bitno je spomenuti koje 3 vrste komunikacija postoje u IoT međuodnosima, to su[28]:

- komunikacija stvar s ljudima
- komunikacija između stvari
- komunikacija između uređaja (M2M)



Slika 6. IoT

Internet stvari jedan su od glavnih elemenata Industrije 4.0 u proizvodnji. Po podacima IDCa, objavljenih u 2017.godini potrošnja u proizvodnoj industriji na IoT iznosila je 178 milijardi dolara u 2016.godini, duplo više od transportne industrije koja je druga po investicijama u IoT. Pretpostavlja se da će proizvodna industrija ostati prva po IoT potrošnji sigurno do 2020.godine.

Zašto je tako?

Proizvodnja obuhvaća brojne aktivnosti. Dugačak je put od ulaska sirovca do gotovog proizvoda te neizbježno dolazi do isprepletanja posla s nabavom, logistikom i transportom robe. Ako sagledamo proizvodnju kao proces u kojem se sirovac pretvara u proizvod, ili se od jednostavnijeg proizvoda, dodavanjem vrijednosti, stvara složeniji možemo vidjeti prilike za ugradnju Internet stvari, neke od njih su:

- upravljanje imovinom

- inteligentno održavanje
- optimizacija rada
- planiranje proizvodnje
- praćenje uskih grla
- praćenje vozila
- sigurnost radnika
- pametna ventilacija i upravljanje kvalitetom zraka
- praćenje otrovnih tvari [29]

Već sada postoje gotova rješenja primjerice za pametno upravljanje logistikom gdje se na sva transportna vozila ugrađuju senzori spojeni na mrežu (IoT) koji uživo pružaju informaciju operateru zaduženom za logistiku o pozicijama, zauzetosti, radniku koji radi, kapacitetu, i stanju vozila. Operater može pratiti u stvarnom vremenu situaciju u pogonu, reagirati promptno, prepoznati uska grla te ih nakon toga, uz pomoć simulacija i riješiti.



Slika 7. Pametno upravljanje logistikom

#### 4.5 Kibernetička sigurnost

Umrežavanje donosi određene opasnosti. Iz tog razloga, jedna od glavnih grana Industrije 4.0 jest i kibernetička sigurnost. Potrebe za zaštitom kritičnih industrijskih sistema i proizvodnih linija od hakerskih napada svakim danom rastu.

2009.godine, virus zvan Stuxnet, preuzeo je kontrolu nad radom nuklearnog reaktora u Iranu nanoseći im veliku štetu. Taj virus je ubačen preko USB memorije u sustav gdje se automatski



proširio u sve sektore. Stuxnetova sofisticiranost služi kao moćan primjer potencijalnih kibernetičkih napada kao oružja u umreženom svijetu. Bitka definitivno nije ravnopravna, organizacije moraju štiti širok spektar tehnologije, dok napadači trebaju samo prepoznati najslabiju kariku i tamo napasti. [30]

U Industriji 4.0, gdje je sve međusobno povezano, u pametnim tvornicama kojima se može upravljati preko mobitela, kibernetička zaštita je težak i na dnevnoj bazi unaprijeđivan proces. Naravno, ne susreću se s jednakim vanjskim prijetnjama pametna tvornica koja se bavi obradom metala i iranski nuklearni pogon, stoga je potrebno naći optimum zaštite.

Kibernetička zaštita mora postati integralni dio strategija razvitka pametne tvornice od samog početka. Ako se o IT zaštiti razmišlja na samom kraju transformacije, tada je već kasno.

Svaka organizacija mora postaviti okvire zaštite koji im najbolje odgovaraju. Ne postoje neki standardni zaštitni niti gotov recept za kibernetičku sigurnost. Dodatne tehnologije koje digitalna transformacija donosi sa sobom predstavljaju izazove za zaštitu te bi svaka organizacija trebala imati spremne reakcije za slučaje napada, u obliku dodatnih offline memorija, spremnih IT timova za promptnu reakciju te PR za krizno komuniciranje gdje se svaka minuta računa. Ništa se ne smije prepustiti slučaju.

Poduzeća koja smatraju dovoljnim samo pratiti regulative i sigurnosne standarde industrije neće se dobro provesti. Regulative su reaktivne te predstavljaju minimume zaštite. Vrlo rijetko su dovoljne za zaustaviti napadače koji moraju pronaći samo jednu slabu točku, Ahilovu petu organizacije kako bi dobile kontrolu i načinile štetu. [30]

Osnovni postulati IT protekcije [30] su:

- osigurajte se - procijenite rizike, procijenite slabe točke, gdje stvarate dodatnu vrijednost, jesu podaci klijenata sigurni, imate li backup, koliko je tok vrijednosti siguran?
- opreznost na prvom mjestu - pratite promjene na mrežama, spojene uređaje, osoblje, svaka neplanirana izmjena može predstavljati ugrozu
- budite fleksibilni - nesreće se mogu dogoditi, no koliko brzo možete odgovoriti? Koliko vam treba za vratiti se u normalan rad? Kako normalizirati poslovanje?



Slika 8. Kibernetička sigurnost

#### 4.6 Internet u oblacima

S obzirom na to da je cilj Industrije 4.0 općenita povezanost svih elemenata sustava, potreban je zajednički prostor za dijeljenje podataka. Podaci više ne mogu biti spremljeni offline, izvan mreže jer su onda dostupni samo lokalnoj jedinici. Rješenje je internet u oblacima.



Slika 9. Cloud

Podaci se sele na online servere gdje su dostupni svim jedinicama koji imaju odobrenje za pristup. Istovremeno, “cloud” postaje sve brži i stabilniji te memorija sve jeftinija i dostupnija. Definicija interneta u oblacima je kolekcija IT usluga za koje organizacija koja ih koristi plaća pretplatu, ovisno o potrebama. [31]

Najpoznatiji pružatelji usluga interneta u oblacima su:

- Microsoft OneDrive
- Dropbox
- Amazon Web Services
- Google Drive



**Slika 10. Dropbox**

#### **4.7 Aditivna proizvodnja**

Aditivna proizvodnja se trenutno najviše koristi za izradu prototipova te još uvijek ne može zamijeniti tradicionalni način proizvodnje. U kontekstu Industrije 4.0, aditivna proizvodnja, što je samo formalniji naziv za 3D printanje, koristit će se sve više i više za izradu malih serija proizvoda. 3D printanje obuhvaća razne metode i tehnologije kao što su ekstrudiranje plastike, ubrizgavanje polimera, lasersko sinteriranje. Neke tehnologije služe za posebne namjene kao što su dizajn nakit ili modeliranje zubala. Ograničavajući faktor su i dalje visoka cijena

proizvodnje i limitirani izbor materijala koji se mogu obrađivati, no potencijal za disrupciju postoji te se očekuje da će većina proizvodnih poduzeća imati dodira s aditivnom proizvodnjom u idućih 5 godina.

Prvi 3D printeri osmišljeni su još u prošlom stoljeću s namjerom brze proizvodnje prototipova. No, kao alat za fleksibilnu proizvodnju malih količina proizvoda visoke kompleksnosti aditivna proizvodnja ima potencijal radikalno promijeniti način poslovanja mnogih tvrtki. Disrupcija se već događa. Neka poduzeća rutinski “printaju” proizvode od cipela do dijelova za avione po ekonomičnijim uvjetima od tradicionalnog načina.[33]

3D printanje može se vršiti globalno, ne samo u tvornici. U budućnosti, kada će svako kućanstvo imati mogućnost 3D printanja, moći se po mnogo povoljnijoj cijeni na internetu kupiti “nacrt” odnosno “pravo na proizvodnju” i u svojoj kući proizvesti ono što trebaju.

Prednosti za korisnika su mnogobrojne, no od najbitnijih to je ušteda i rok isporuke, kojega gotovo i da nema. Odnosno kao rok isporuke može se računati vrijeme potrebno za “printanje”. Poduzeće pak nema troškove proizvodnje već samo “patent na proizvod” koji prodaju preko interneta, kao danas Kindle knjige. Nema troškova isporuke niti troškova proizvodnje. Summa summarum, dolazi do digitalizacije fizičkih proizvoda.

Doći će i do zamjetnih promjena na razini industrije. Proizvodna industrija poznata je po visokim investicijskim troškovima. Barijere za ulazak u mnoge industrije će pasti što će olakšati ulazak u poduzetništvo za nove igrače. Zbog mogućnosti “printanja” rezervnih dijelova, pružatelji logističkih usluga mogli bi se suočiti sa smanjenom potražnjom za usluge brze isporuke (na kojima imaju više margine zarade). [33]

Glavne prednosti aditivne proizvodnje:

- “just in time” proizvodnja direktno na lokaciji potrebe - Kupci će si proizvode moći “isprintati” ili sami doma ili na “prodajnim mjestima” na zahtjev. Nema potrebe za zalihama.
- neograničena individualizacija - Aditivna proizvodnja omogućuje masovnu proizvodnju visoko prilagođenih, individualiziranih proizvoda
- “outsourcanje” proizvodnje rezervnih dijelova - Mogućnost printanja rezervnih dijelova na lokaciji gdje nam treba u vrijeme kada nam treba, bez čekanja. [36]

#### **4.7.1 Aditivna proizvodnja - materijali**

Inženjerstvo materijala nužno je za razumjeti aditivnu proizvodnju. Znanstvenici rade na otkrivanju materijala koji se mogu koristiti za uspješnu proizvodnju. Za sada najviše je polimera, no s tehnološkim napredcima Industrije 4.0, spektar materijala će se samo širiti, a s time i proizvoda koje može proizvesti. S obzirom na to da i dalje polimeri predstavljaju najveći udio materijala korištenih u aditivnoj proizvodnji, red je započeti s njima.

ABS - Acrylonitrile Butadiene Styrene je polimer primjenjiv u izradi mnogih predmeta među kojima su najpoznatije LEGO kockice. Najvažnija svojstva ABS-a su otpornost na udar i tvrdoća. [37] Cijena ABS-a je relativno niska i obično se kreće između tržišnih cijena polipropilena (PP) i polikarbonata (PC). Najčešće se koristi. Ima bolja mehanička svojstva od PLA, ali je ujedno i zahtjevniji za tiskanje.

PLA - Polylactic Acid postao je popularan i atraktivan materijal u 3D industriji zbog svoje potpune biorazgradivosti. PLA se dobiva iz biomaterijala, npr. iz kukuruzne škrobi, korijenja bilje tapioke te šećerne trske. [37] Ima bolja estetska svojstva od ABS.

FlexPol - polimer koji ima elastična svojstva. Prilikom fizičkog naprezanja materijal mijenja svoj oblik te se nakon prestanka djelovanja sile vraća u prvobitni oblik. [37]

NYLON - vrlo čvrsti materijal koji ima veliku otpornost na mehaničko naprezanje. [37]

LAYBRICK - nastaje miješanjem polimera i prašine kamena. Proizvodu izrađenom tehnikama 3D printanja daje izgled kamena. [37]

WOODLAY - nastaje miješanjem polimera i drvene piljevine. Proizvodu izrađenom tehnikama 3D printanja prividno daje osjećaj kao da je izrađen od drveta. [37]

Dugi niz godina, aditivnoj tehnologijom moguće je bilo dobiti proizvode samo od polimera, no danas više nije tako. S obzirom na to da su metali materijali koji se najčešće koriste u strojarstvu spomenuti ću gdje pronalaze svoju ulogu u aditivnoj proizvodnji. Aditivna proizvodnjom

moгуće je dobiti proizvode bazirane na aluminiju, titaniju i čeliku metalurgijom praha. Znanstveno područje koje se bavi aditivnom proizvodnjom metala naziva se MAM (metal additive manufacturing). Svojstva metalnih dijelova jako ovise o njihovoj mikrostrukturi koja poprilično varira u MAM proizvodnji. Preduvjet za širu industrijsku upotrebu jest rješavanje problema cijene, proizvodne brzine, poboljšanje postignute tvrdoće i krutosti, veća kvaliteta površina te postizanje homogenije mikrostrukture. [32]

U aditivnoj proizvodnji često se spominju pametni materijali budućnosti. Što je to? Materijali koji mijenjaju svojstva ili oblik ovisno o vanjskim uvjetima. Zbog sposobnosti promjene svojstva, često se nazivaju i 4D materijalima za printanje. Koriste se kod fleksibilnih robotskih sistema, samorastućih struktura i pri kontroliranom sklapanju. [32] 4D materijali koji se najviše koriste su:

- memorijske legure
- memorijski polimeri

Memorijske legure specifične su po visokoj elastičnosti i mogućnosti rekonstrukcije oblika izlaganjem višim temperaturama. Memorijska legura nikla-titanija nalazimo u raznim primjenama, od biomedicinskih implantanata do elektromehaničkih uređaja. Memorijski polimeri osjetljivi su na vanjske stimulanse: svjetlo, vlagu i temperaturu. Zbog biokompatibilnosti, primjenu sve više nalaze u medicinskim svrhama. Elektoreagirajući memorijski polimeri mogu vanjskom stimulacijom promijeniti svoju svojstva krutosti. [32]

Uglavnom, aditivna proizvodnja stimulira korištenje novih pametnih materijala u inovativne svrhe. U sklopu Industrije 4.0, sinergijom novih materijala i mogućnostima aditivne proizvodnje doći će do inovacija koje će disruptirati cijelu proizvodnu industriju.



**Slika 11. Okvir bicikla**

No, dosta teorije, vrijeme je za nekolicinu primjera iz industrije.

Na slici iznad prikazan je okvir bicikla dobiven 3D printanjem. Metalni okviri bicikla obično se rade postupkom selektivnog taljenja ili srašćivanja praha čelika u kojem se upotrebljava laser. Na nizozemskom sveučilištu Delft University of Technology aditivnim postupkom nataljivanja izrađen je bicikl od nehrđajućeg čelika. Za razliku od tradicionalnih 3D pisača koji izrađuju tvorevine horizontalno na ravnoj površini, upotrijebili su 3D pisač tvrtke MX3D koji robotskom rukom izbacuje mlaz smole na horizontalnim ili vertikalnim površinama. Ti stupovi smole mogu biti zaobljeni i povezani zajedno dok se izrađuju i završno očvršćuju. Taj novi postupak 3D tiskanja zavarenog metala počinje spuštanjem kapljice rastaljenog metala, zatim se, nakon što očvrstne, dodaje druga kapljica na vrh te se taj postupak nastavlja dok se ne proizvede cijeli metalni stup. Kontrolom zavarivanja moguće je kontrolirati usmjerenje stupaca. Pri tome nisu potrebni popratni materijali te se mogu načiniti prilično velike konstrukcije. Okvir bicikla napravljen je u nekoliko glavnih dijelova koji se zatim ručno zavaruju jedan s drugim. Takav gotov bicikl teži kao i tradicionalni bicikl s čeličnim okvirom te se može voziti i po neravnim kamenim ulicama. [34]

Sljedeći zanimljiv primjer upotrebe aditivne proizvodnje u kombinaciji s recikliranjem je Adidasov inovativni koncept obuće. Riječ je o prvom prototipu cipele na svijetu kojemu je gornji dio izrađen samo od prediva i filamenata dobivenih recikliranjem otpada iz oceana. Sastoji se od gornjeg dijela koji je izrađen od plastike prikupljene iz oceana i središnjeg đona koji je napravljen 3D tiskanjem od recikliranog poliestera i mreža. [35]



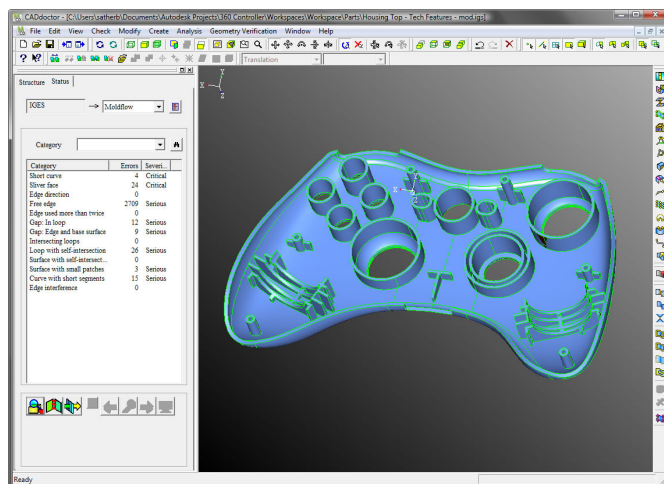
**Slika 12. Adidasova tenisica [35]**



#### 4.7.2 Kako izgleda postupak aditivne proizvodnje? [38]

### 1. CAD

Prvo je potrebno napraviti digitalni model u nekom od CAD programa. Zavisno o tehnologijama proizvodnje potrebno je poštivati pravila struke oko konstrukcije geometrije nekih dijelova. CAD model moguće je dobiti i suprotnim smjerom, obrnutim inženjerstvom, skeniranjem gotovog modela.



Slika 13. CAD modeliranje [39]

### 2. STL pretvorba

Ovaj korak predstavlja najveću razliku u odnosu na tradicionalnu proizvodnju. CAD model se treba pretvoriti u STL (stereolitografija.) datoteku. Sljedeći korak je konverzija datoteke u G-kod (programski jezik numeričkog upravljanja) koji se koristi za upravljanje automatiziranim alatnim strojevima (uključujući CNC strojeve i 3D pisače).


### 3. Proizvodnja

3D printeri često sadrže brojne dijelove čije je ispravno i redovito održavanje te kalibracija ključna za izradu preciznih izradaka. U pisač se ubacuje sirovac za tiskanje. Sirovci za aditivnu proizvodnju često imaju ograničen rok trajanja i zahtijevaju pažljivo rukovanje.

Započinje se proizvodnja. Većina strojeva za aditivnu proizvodnju je automatizirana te će do greške u ovoj fazi doći samo ako postoji greška u programu ili nestane materijala.


### 4. Uklanjanje izratka

Ovisno i korištenim materijalima, tehnika, ali i izgledu proizvoda, vađenje izratka iz pisača može biti trivijalno, ali i veoma komplicirano zahtijevajući posebne vještine operatera. Kod većine jednostavnih dijelova za kućnu upotrebu, postupak završava uklanjanjem iz printer.



Slika 14. Izradak s postoljem [38]

No ako se radi o tehnički zahtjevnim konstrukcijama, treba pažljivo odvojiti predmet od postolja i gradivnog materijala.




Slika 15. Vadenje izratka [38]

#### 4. Završna obrada

Završna obrada ovisi o korištenoj tehnologiji aditivne proizvodnje. Konkretno, u ovom primjeru sa slika radi se o SLA tehnici koja zahtjeva da materijal stari pod UV svjetlom prije daljnje isporuke. Metalni izratci trebaju proći kroz postupak popuštanja, dok proizvodi dobiveni FDM tehnikom ne zahtijevaju nikakvu završnu obradu.

Većina materijala za aditivnu proizvodnju može se brusiti, propuhivati zrakom pod visokim tlakom, polirati i bojati prije isporuke kupcu.



Slika 16. Držač kartica [38]

#### 4.8 VR i AR

“Virtual reality” odnosno virtualna stvarnost jedna je od tehnologija koja je sve zastupljenija u Industriji 4.0.

Definicija virtualne stvarnosti, naravno, dolazi iz definicija "virtualno" i "stvarnost". Virtualno znači nešto blizu nečemu drugome, a stvarnost je ono što mi doživljavamo kao ljudska bića. Dakle, pojam "virtualna stvarnost" zapravo znači "blizinu stvarnosti”.

Ljudi poznaju svijet kroz osjetila i sustave percepcije. U školi smo svi naučili da imamo pet osjetila: okus, dodir, miris, vid i sluh. No to su oni glavni i najočitiji. Istina je da ljudi imaju puno više osjetila kao npr. osjećaj ravnoteže. Ti drugi osjetilni ulazi, odnosno “inputi” ako gledamo IT rječnikom kao i posebna obrada tih informacija unutar mozga osiguravaju nam da imamo bogat protok informacija iz okoline u naše umove.

Sve što znamo o našoj stvarnosti dolazi putem naših osjetila. Drugim riječima, naše cjelokupno iskustvo stvarnosti jednostavno je kombinacija osjetilnih informacija i mehanizama koji stvarao smisao sinergijom tih informacija.

Stoga je jasno da, ako možete promijeniti ulazne podatke, odnosno osjetilne signale, naša percepcija stvarnosti također bi se mijenjala kao odgovor na nju. Vidjeli bi verziju stvarnosti koja zapravo nije stvarna, ali mozak bi je shvaćao kao stvarno. Upravo to je ono što nazivamo VR.

Dakle, virtualna stvarnost podrazumijeva podraživanje naših osjetila računalom generiranim virtualnim okruženjem. [14]

S druge strane AR iliti augmented reality se možda ne čini toliko atraktivnim koliko VR no pruža velike mogućnosti primjene. No što je AR?

Poboljšana verzija stvarnosti u kojoj se izravnim ili neizravnim prikazima stvarno fizičko okruženje nadograđuje računalno generiranim informacija o okolini te korisnik daje bolji uvid i više detalja njegovoj percepciji okoline. [15]

#### **4.8.1 Primjena VR i AR**

VR se trenutno najviše koristi u industriji zabave, posebice u filmovima i igricama. Industrija zabave je, prije svega, teška više milijardi dolara, a potrošači pate za inovacijama. No, virtualna stvarnost ima i mnogo drugih, ozbiljnijih mogućnosti primjena.

Gdje god je u praksi preskupo, nepraktično ili preopasno djelovati, virtualna stvarnost je odgovor. Od treninga pilota vojnih aviona (uštede su višestruke) do treninga budućih kirurga, virtualna stvarnost nam omogućuje da stvarne rizike zamijenimo virtualnim. U studiji iz 2008.godine[16] 68% od 735 specijalista kirurgije ocijenilo je trening VR odličnom ocjenom.

Znanstvene svrhe također predstavljaju veliko područje u kojem se umjetna stvarnost može koristiti. Sve radnje na atomskoj i molekularnoj razini nevidljive su ljudskom oku bez pomoći elektronskog mikroskopa. Pretpostavimo da želite konstruirati nove materijale ili lijekove te želite eksperimentirati s molekularnim ekvivalentom LEGO kockica. U tom slučaju odgovor je umjetna stvarnost. Umjesto borbe s brojevima, jednadžbama ili dvodimenzionalnim crtežima molekularnih struktura, možete složiti kompleksne spojeve ispred vaših očiju. [17]


Industrijski dizajn i arhitektura sve više postaju zastupljeni u industriji VRa. Još do prije par desetak godina, arhitekti su radili modele zgrada i objekata iz papira. Digitalizacijom društva, počeli su koristiti instrumente računalnog dizajna kao što je AutoCAD, SolidWorks i slično. No što ako na sve to dodamo još VR? Dobiye se kombinacija gdje će kupci moći prošetati kućom, stanom ili brodom koji planiraju kupiti prije nego je prva cigla zabijena u zemlju. Cijela industrija građevine može biti transformirana.

Budući da se cijena primjene virtualne stvarnosti smanjuje i postaje dostupna sve široj bazi potrošača, možete očekivati porast korištenja u drugim industrijama.

Primjene AR kreću se od jednostavnih tekstualnih notifikacija koje se pojavljuju na ekranu naočala do kompliciranih instrukcija kako primjerice provesti neku kompliciranu operaciju. U kombinaciji s glasovnim uputama može zamijeniti čak i asistente kirurgu primjerice eliminirajući ljudski faktor greške. Ključna stvar je da su informacije pružene vrlo aktualne i relevantne za ono što trenutno radite.

Postoje 4 vrste poboljšane stvarnosti:

- poboljšana stvarnost s označivačem
- poboljšana stvarnost bez označivača
- projicirana poboljšana stvarnost
- vizualizirajuća poboljšana stvarnost [15]



Slika 17. AR [15]



Kod poboljšane stvarnosti s označivačem korisnik senzorom, najčešće kamera na pametnom mobitelu očitava neku vrstu vizualnog koda (bar kod / QR kod) te dobiva rezultat. Aplikacije temeljene na tom sustavu rada koriste označivače kako bi razlikovale traženi objekt od okoline. [15]



**Slika 18. AR bez označivača [15]**

AR bez označivača jedan je od najupotrebljivanijih sustava. Koristi GPS, akcelerometar, žiroskop i/ili digitalni kompas za pozicioniranje korisnika. Ovaj sustav u potpunosti iskorištava mogućnosti tehnologije pametnih telefona. Upotrebljava se kod mapiranja ruta, pronalaženje obližnjih točki interesa i snalaženja u prostoru. [15]


Projicirana poboljšana stvarnost radi na principu projekcije holograma u stvarnost. Omogućuju ljudsku interakciju s podlogom šaljući svjetlost na stvarnu površinu, a zatim prepoznajući ljudsku interakciju te projicirane svjetlosti. [15]

Vizualizirajuća poboljšana stvarnost djelomično ili potpuno zamjenjuje izvorni izgled objekta s novim prikazom istog tog objekta. U ovom sustavu, identifikacija objekta igra ključnu ulogu jer aplikacija ne može zamijeniti izvorni prikaz s poboljšanim ako ne može utvrditi što je treba zamijeniti. Primjer je interaktivni IKEA-in katalog gdje kupci mogu vizualizirati

raspored kućanskih namještaja po osobnoj preferenciji približavajući im percepciju stvarnog izgleda u slučaju kupovine. [15]



**Slika 19. Vizualizirajuća poboljšana stvarnost**



**Slika 20. Projicirana poboljšana stvarnost**

## 4.9 Umjetna inteligencija

Umjetna inteligencija (UI) je naziv koji pridajemo svakom neživom sustavu koji pokazuje sposobnost snalaženja u novim situacijama (inteligenciju). Engleski naziv za umjetnu inteligenciju je artificial intelligence skraćeno AI.

Uobičajeno je da se to ime pridaje računalnim sustavima. Izraz se neosnovano primjenjuje i na robote, budući da njihov sustav ne mora nužno biti inteligentan. [40]

Umjetna inteligencija je usko povezana s robotikom ali i računalnim sustavima budući da im pruža sposobnost snalaženja u novonastalim situacijama.

Izraz je koji se vrlo često upotrebljava u kontekstu Industrije 4.0 te globalne digitalne transformacija društva. Također, svakih par mjeseci možemo čitati o potencijalnim opasnostima razvitka umjetne inteligencije. Daleko smo od dana kada će AI sustići nivo ljudske inteligencije.

Na pojam umjetne inteligencije ne može se gledati izolirani. Umjetna inteligencija ne funkcionira bez učenja, a učenje se postiže iz prethodnih rezultata nekog procesa. Dolazimo do povezanosti big data i AI koji su načelno povezani. Analizama velikih baza podataka te utreniravanjem umjetne inteligencije moguće je postizati predikcije. Te predikcije već se sada rade u fazama kvantnog trgovanja dionicama gdje računalni programi, na bazi parametara kao što su naprimjer povijesno kretanje cijena, vremenska prognoza, dan u tjednu prognozira buduće trendove. Industrijske analize predviđaju veliki rast tržišta umjetne inteligencije. Economist Intelligence Unit proveo je anketu gdje je 75% izvršnih direktora kazalo da u iduće 3 godine planiraju implementaciju sustava baziranih na umjetnog inteligenciji u svoja poduzeća, dok je njih 3% već to obavilo. [41] S obzirom na to da je ovaj rad baziran na proizvodni proces, pokušat ću približiti trendove gdje umjetnu inteligenciju možemo iskoristiti u proizvodnoj industriji.

### 4.9.1 AI u primjeni

Amazon je za 775 milijuna dolara akvizirao Kiva, tvrtku koja inteligentno automatizira proces pakiranja u logistici. Rezultati su obećavajući. Vrijeme od trenutka narudžbe do isporuke skraćeno je sa 75 minuta na 15 minuta, kapacitet zaliha povećan je za 50%, a operativni troškovi sniženi za 20%.



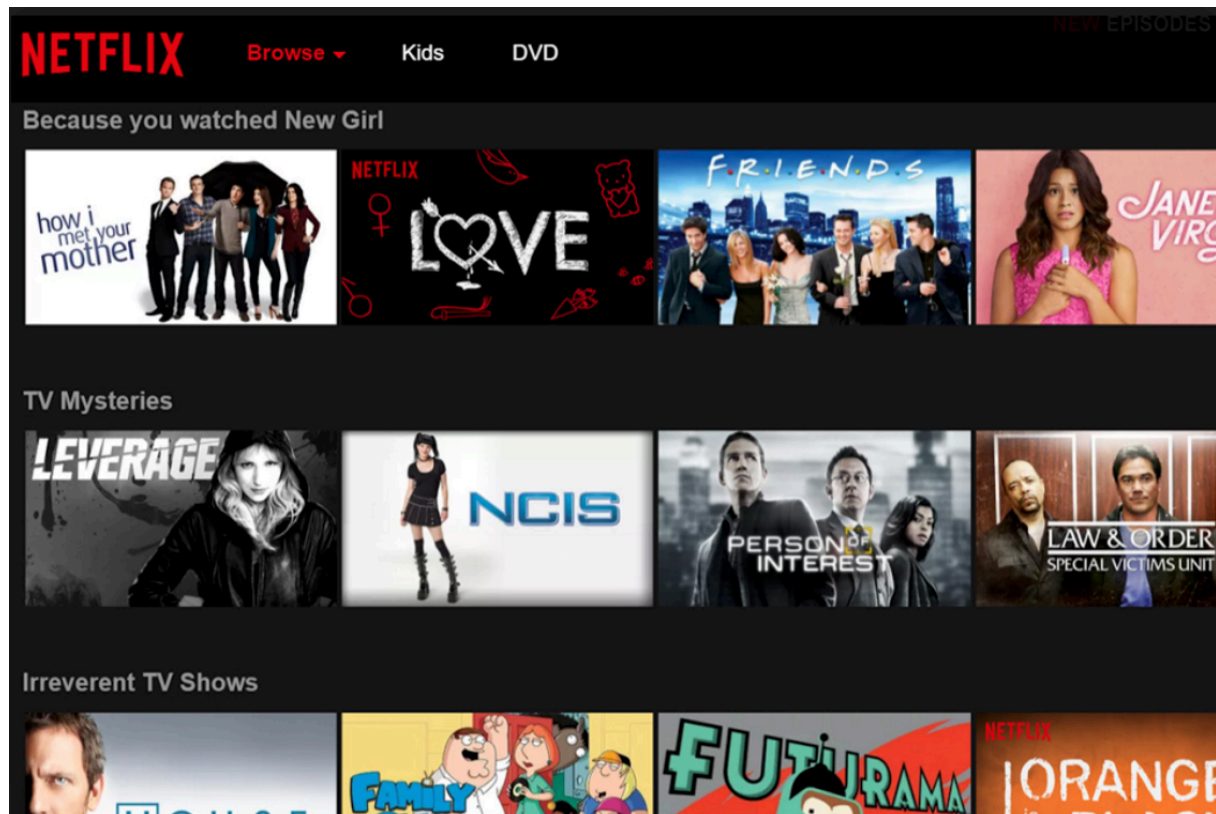


**Slika 21. KIVA inteligentni robot [43]**

Drugi primjer uspješne implementacije umjetne inteligencije u svoje poslovanje je Netflix. Algoritam koji na osnovi pogledanih serija i filmova predlaže što bi vam se moglo svidjeti. Brzo usmjeravanje korisnika na ono što žele može predstavljati razliku između dobivenog i izgubljenog korisnika. Interno istraživanje je pokazalo da ako korisnici ne pronađu film ili seriju koju traže unutar 90 sekundi odustanu od daljnjeg pretraživanja. Procjene Netflix-a su da su kvalitetnijim preporukama uštedjeli milijardu dolara godišnje na zadržavanju korisnika. [41]

Najjednostavnija primjena umjetne inteligencije je već ranije spomenuta predikcija. Na sve zahtjevnijem tržištu, tvrtke moraju anticipirati buduće trendove da bi postigle kompetitivnu prednost. AI omogućuje tvrtkama da brže i točnije optimiziraju njihov tok vrijednosti te ponude kupcima. AI, uz dobre ulazne podatke, prepoznaje trendove i uzorke koje ljudsko oko ne uočava. Što to znači u proizvodnji?

Predviđanje potreba za određenom robom, kako se ne bi nakupljale zalihe te smanjili troškovi logistike. Anticipiranje trendova u blagdansko doba kako ne bi ostali bez proizvoda u najgore vrijeme te stvorili oportunitetni trošak.



Slika 22. Netflix preporuke [44]

Prognoze kažu da AI ima potencijal smanjiti troškove transporta i skladištenja za 5-10%, administracije 25-40%. Ukupni uštede zaliha moguće su od 20 do čak 50%, ovisno o industriji. [42]

#### 4.9.2 Primjer u proizvodnji [41]

Segmenti koje svako veće proizvodno poduzeće ima su:

- nabava i projektiranje
- proizvodnja
- marketing
- logistika

U svakom od tih sektora može se naći mjesto gdje primijeniti umjetnu inteligenciju. Pitanje je samo cost-benefit analize koliko je isplativo, odnosno opravdavaju li rezultati potrebnu investiciju.



**Slika 23. Pametna tvornica [45]**

U odjelu za projektiranje AI može pomoći pri dizajniranju modela kako bi bio optimiziran na određene zahtjeve koje imamo, automatizirati postupak verifikacije dobavljača (njihov rejting, pouzdanost, podatke o poslovanju) te anticipirati povećane potrebe za nabavom određenih dijelova.


Pri upravljanju proizvodnjom, integracija umjetne inteligencije dovesti će do povećane produktivnosti i efikasnosti te snižavanja troškova kroz automatizaciju procesa montiranja, bolju sljedivost i eliminaciju škarta, limitiranje vremena prepravaka te skraćivanjem vremena isporuke materijala.

U marketingu i prodaji primjena je vrlo opširna. Ciljanje prave publike, uz optimalnu cijenu nikad nije bilo lakše. AI može u potpunosti automatizirati proces optimiziranja prodajnih cijena ovisno o potražnji.

Logistika je često zanemarivani segment u optimizaciji toka vrijednosti. U kombinaciji umjetne inteligencije, autonomnih robota (primjer Amazon Kiva ranije naveden) te kvalitetnih rješenja



za upravljanjem skladištem moguće je postići visoke uštede u vremenu i troškovima. AI može prilagoditi kamionske rute, odabir vozila, operatera, potrošnju te automatski rasporediti radnike po smjenama u skladištu ovisno i potražnji koja stiže iz odjela prodaje.



Slika 24. Pametno upravljanje skladištem [46]

## 5. Ekosustavi digitalizacije

Proces digitalizacije društva doveo je do stvaranja platforma pružaju korisnicima zaradu. Stvoreni su ekosustavi koji povezuju dobavljače u širem smislu te riječi i klijente koji su potraživači. Dobavljači su svi koji kroz ekosustav zarađuju, dok su klijenti svi oni koji plaćaju usluge dobavljačima. Ekosustav služi samo kao platforma koja osigurava određene uvjete za poslovanje te uzima proviziju za sve odrađene transakcije.

Najveći ekosustavi današnjice su Amazon, Ebay, Fiverr, Alibaba, Uber, Airbnb i Booking.



**Slika 25. Airbnb [47]**

Zanimljivo je da Uber, najveći “taxi” prijevoznik današnjice zapravo ne posjeduje niti jedan automobil. Booking, najveći “hotel lanac” današnjice ne posjeduje niti jedan hotel.




**Slika 26. Uber [48]**

Airbnb i Booking doveli su do toga da svatko tko posjeduje apartman danas može postati poduzetnik i uspješno ga iznajmljivati. Ništa novo, bilo je to moguće i prije, no puno teže. Popunjenost je bila znatno niža. Airbnb eliminirao je glavni trošak iznajmljivače, takozvani “middleman”, agencije.

Uber je prodrmao i liberalizirao, inače konzervativno, taxi tržište u cijelom svijetu. Regulatorne probleme imaju na svakodnevnoj razini, no Uber je omogućio svakom pojedincu koji posjeduje vozilo da s njime i zarađuje. Potrebno je samo registrirati se na aplikaciju, prijaviti obrt i vozilo i spremni ste za vožnju. S druge strane, korisnicima Uber aplikacije, među kojima sam i ja od prvoga dana kada je postao dostupan u Republici Hrvatskoj Uber je omogućio povoljniju, bržu i transparentniju uslugu. Uz pojam taksija godinama su se vezivale asocijacije netransparentnosti. Kada dođete u novi grad, teško je znati koja je taksi tarifa i koja je ruta najbrža. Otvara se prilika za prevaru. No Uber koristi digitalne tehnologije da a priori narudžbe vožnje prikaže korisniku optimiziranu rutu i okvirnu cijenu. Nadalje omogućava korisniku i da ocjenjuje vozače te tako tržište odrađuje svoje i eliminira devijacije.

Sve u svemu, jedna vrlo jednostavna usluga dovela je do digitalne transformacije taksi tržišta i stvaranja platforme koja je omogućila brojim vozačima izvor dodatnih prihoda, a korisnicima pojednostavila cijeli proces taksi usluge.



Slika 27. GuestReady [50]

Airbnb i Booking napravili su identičnu stvar u drugoj industriji, industriji najma. Razlika je što je Booking startao kao platforma za rezervacije smještaja u hotelima, a kasnije proširio dijapazon ponude i na privatne smještaje odnosno apartmane, dok je Airbnb platforma samo za apartmane.

Sistem je vrlo sličan Uberu. Strana ponude su iznajmljivači koji su kroz te platforme dobili pristup globalnom tržištu, dok gosti iz cijelog svijeta mogu u dva klika iznajmiti apartman gdje god žele. Za svakog domaćina kao i gosta ostavljaju se rejting što stvara efekt zdrave konkurencije.

Velika prihvaćenost Airbnb-a ekosustava otvorila je mogućnost manjim tvrtkama da ponude komplementarne usluge širem svijeta. Brojna poduzeća otvorena su u svrhu upravljanja nekretninama, radi povezanih usluga čišćenja, prijevoza gostiju do i od aerodroma, provjere gostiju pa čak i savjetovanja oko cijena. No nisu samo lokalne tvrtke koje iskorištavaju mogućnosti tih platformi rezultat. Neki startupi postižu višemilijunske vrijednosti bazirano na pružanju podsluga Airbnb sustavu. Dharma Home Suites i Niido dobile su 200 milijuna dolara teške investicije od korporacije Brookfield za izgradnju AirBnb brendiranih apartmana za kratki najam. [49]

GuestReady, švicarski start-up s uredima u Kuala Lumpuru, Londonu, Parizu, Singapuru i Hong Kongu pruža gotova rješenja za iznajmljivače na Airbnb. Usluge uključuju sve od fotografiranja apartmana, administrativnih poslova, marketinga, čišćenja i primanja gostiju.

GuestReady je od zainteresiranih investitora prvo dobio investiciju od 750.00 dolara, a krajem 2017.godine dodatnih 3 milijuna dolara. Već sada je procijenjena vrijednost više desetaka milijuna dolara. [49]

Što se tiče Amazona i Ebaya, stotine tisuća poduzeća diljem svijeta opstaju samo zbog njih. Mnogim distributerima većina prometa upravo dolazi preko tih stranica. Fiverr i slične "freelance" platforme omogućile su svakom pojedincu prodaju svojih vještina na globalnom tržištu. Danas programer iz Zagreba može iz vlastitog dvorišta raditi paralelno 5 projekata, svaki za klijenta na drugom kontinentu.





**Slika 28. Amazon HQ [51]**

Ekosustavi su tu samo kao platforme koje pružaju:

- sigurnost
- jednostavnost
- pristup tržištu

Glavi cilj im je spojiti ponudu i potražnju.



## 6. Povezivanje leana i digitalizacije kroz dualnu strategiju

U uvodnom dijelu objasnio sam pojmove Industrije 4.0, glavne tehnologije i trendove te na kraju i ekosustave koji su rezultat digitalne transformacije industrije.

No kako u praksi povezati lean menadžment i digitalizaciju?

Kako uspješno transformirati poduzeće?

Hrvatska industrija na razini je između Industrije 2.0 i 3.0 stoga je u većini primjera teško odmah krenuti na digitalizaciju. Nema smisla digitalizirati procese koji su zastarjeli i neefikasni. Procese prvo moramo optimizirati, tek nakon toga ih digitalno transformirati. Stoga prvi korak mora biti implementacija leana u poduzeća.

Profesor Nedeljko Štefanić s Fakulteta strojarstva i brodogradnje razvio je sustav dualne transformacije poduzeća koji obuhvaća lean i digitalnu transformaciju.

Duana transformacija je strategija modernizacije poduzeća kroz optimiziranje procesa lean alatima te zatim digitalizacijom tih procesa.

Lean transformaciju čine 5 koraka. O svakom će kasnije biti rečeno detaljnije. Tih 5 koraka su:

- Kaizen
- 5S
- Standardizacija
- VSM
- Kvaliteta

Digitalna transformacija vrši se u 7 koraka. Procesi nisu serijski već treba procijeniti, ovisno o spremnosti poduzeća, s kojima krenuti i kada. Tih 7 koraka su:

- pametni i povezani proizvodi (IoT)
- Horizontalna i vertikalna integracija
- Optimalno korištenje resursa
- Digitalno znanje i vještine
- Robotizacija

- Standardizacija i pravna regulativa
- Kibernetička sigurnost



Slika 29. Primjenjivost dualne transformacije

Većinu ovih koraka spomenuti su već ranije, u dijelu rada o Industriji 4.0.

## 6.1 Vitka transformacija

### 6.1.1 Što je lean?

Lean nije samo način upravljanja ili način rukovođenja. Lean je cjelokupna filozofija. Lean je način života kompanije koji mora biti shvaćen i usvojen od svih razina menadžmenta, bilo strateškog, taktičkog ili operativnog. Ako jedan nivo zakaže, zakazao je cijeli organizam tvrtke. Lanac je onoliko čvrst koliko je čvrsta najslabija karika u njemu.

Zadatak leana je kontinuirano poboljšavati sigurnost, kvalitetu, uštedu vremena, cijenu i moral ljudi unutar poduzeća.

Lean	Tradicionalni
<b>Strategija</b>	
<b>Biznis model</b> Vođen hipotezama	<b>Poslovni plan</b> Vođen implementacijom
<b>Proces razvoja novog proizvoda</b>	
<b>Razvoj korisnika</b> Izaći izvan ureda i testirati hipoteze	<b>Upravljanje proizvodima</b> Priprema ponude za tržište slijedeći linearan, korak-po-korak, plan
<b>Razvoj</b>	
<b>Agilni razvoj</b> Razvoj proizvoda je iterativan i inkrementalan	<b>Agilni ili "Waterfall" razvoj</b> Razvoj proizvoda iterativno, ili u potpunosti specificiran proizvod prije nego je izrađen
<b>Organizacija</b>	
<b>Timovi za razvoj korisnika i agilni razvoj proizvoda</b> Zapošljavanje za učenje, spretnost i brzinu	<b>Odjeli po funkcijama</b> Zapošljavanje za iskustvo i sposobnost izvršenja
<b>Financijsko izvještavanje</b>	
<b>Metrika koja vrijedi</b> Troškovi pridobivanja korisnika, doživotna vrijednost korisnika, broj korisnika koje startup gubi ( <i>churn</i> ), viralnost	<b>Računovodstvo</b> Račun dobiti i gubitka, bilanca, izvješće o novčanom toku
<b>Greška</b>	
<b>Očekivana</b> Riješena sa iteriranjem na prvotnu ideju i pivotiranjem od onih koje ne funkcioniraju	<b>Iznimka</b> Riješena otpuštanjem izvoditelja
<b>Brzina</b>	
<b>Rapidna</b> Radi se sa "dovoljno dobrim" podacima	<b>Mjerena</b> Radi se sa kompletnim podacima

Slika 30. Lean

Svrishodno je za napomenuti kako lean filozofija nije ograničena na funkcioniranje samo unutar poduzeća, ona se može primijeniti i u neprofitnom sektoru, javnom sektoru, ali i politici. Bit leana je eliminacija nepotrebnih procesa, povećanje kvalitete proizvoda ili usluge, bolja efikasnost i produktivnost zaposlenih te brži prolaz kroz proizvodni proces. Vrijeme je najbitniji resurs lean filozofije.

1997.godine James Womack i Daniel T.Jones pokrenuli su "školu" za lean metodologiju pod nazivom Lean Enterprise Institute te su u svojoj knjizi Lean Thinking naveli 5 osnovnih načela lean proizvodnje. [52]

To su:

- vrijednost
- lanac vrijednosti
- tijek
- povlačenje/pull
- perfekcija

1. Vrijednost - kupci odnosno tržište uvijek definira konačnu vrijednost. Vrijednost je ono što je kupac spreman platiti za nešto što poduzeće nudi. Studije su pokazale da u prosjeku samo 5% potrošenog vremena direktno utječe na konačnu vrijednost. Ostatak vremena troši se načelno na gubitke kao što su čekanja, transport, zastoji, dodavanje funkcija koje nitko od kupaca ne treba niti će koristiti..
2. Lanac vrijednosti - ukupni skup svih aktivnosti, procesa i tokova u proizvodnji, bilo materijalnih ili informacijskih, potrebnih da se od sirovine dobije gotov proizvod. Lean alatima pokušavamo ukloniti ili skratiti procese koji ne dodaju na vrijednosti.
3. Tijek - cilj je neprekidan i kontinuirani tok. Vrijednosni lanac mora biti uglađen i bez smetnji od samog početka do kraja, teći fluidno kao što rijeka teče nizvodno. Prekidi tijekom pridonose gubitcima zastoja i smanjuju konačnu vrijednost.
4. Povlačenje - primjena just in time sistema, odnosno zamjena push u pull procese gdje god je moguće. Ideja koncepta je da se ne stvaraju zalihe i nepotrební inventar bazirano na projekcijama već da se u proizvodnju ide tek nakon dobivanja narudžbe ili pronalaska kupca. Preveliki inventar jedan je od najštetnijih 7 gubitaka za lean poduzeća. Nepotrebne zalihe opterećuju poduzeća financijski, logistički i vremenski.
5. Perfekcija - zadnji od 5 principa proizvodnje je težnja prema savršenstvu. Neprestana iteracija. Nužno je zapamtiti da lean nije statična platforma te zahtjeva konstantno poboljšavanje. Svaki zaposleni mora biti upoznat sa stečevinama leana.

### 6.1.2 Stanje u svijetu

Svijet se dijeli u 3 kategorije država:

- razvijene
- u razvitku
- nerazvijene

Dobar primjer za napraviti usporedbu je bankarska industrija. Bankarska industrija primjer je stabilne industrije, koja nije prva u prihvaćanju novih inovacija (zbog potencijalnog izlaganju riziku), no niti zadnja. Upravo zato prihvatljiv je prosjek za uzeti za usporedbu.

Lean metode visoko su prihvaćene u industriji financijskih usluga na razvijenim tržištima, no brzo dobivaju trakciju na novim tržištima država u razvitku.

U Aziji, Južnoj Americi i Africi, banke koje su izvršile lean transformaciju vratile su uložene troškove u roku od 12 do 15 mjeseci i povećale dobit za 10 do 20 posto u roku od godinu dana.

[4]

Lean banke koje djeluju na tržištima u nastajanju usvajaju transformativne pristupe razvoj i distribuciju proizvoda koji financijske usluge omogućuju pristup korisnicima s niskim prihodima koji ih nikad prije nisu mogli priuštiti. Potreba je akutna: mnoge siromašne obitelji koje se pribjegavaju posuđivanju od zalagaonica ili drugih neformalnih kanala plaćaju pet ili čak deset puta koliko bi platili bankovni kredit. A za banke, vrijednost koju riskira je ogromna: u cijelosti 70 posto globalnog prihoda od bankovnih prihoda u naredne 3 godine očekuje se da će proizaći iz tržišta u nastajanju.

Banke koje su usvojile lean metode pristupa te djeluju na tržištima u razvitku usvajaju nove transformativne pristupe za razvoj i distribuciju financijskih usluga. Potencijalna vrijednost je ogromna. Očekivanja kazuju da će 70% od ukupnog rasta bankovnih prihoda u iduće 3 godine stizati iz tržišta u razvitku.

Osim akvizicije novih klijenata, lean banke uspijevaju širiti lepezu usluga postojećim korisnicima. Jedna afrička banka, nakon lean transformacije, uspjela je povećati prosječan broj proizvoda po kupcu za više od 70 posto u jednoj godini.

Nadalje, kada se banka želi geografski proširiti, nakon što je standardizirala lagani maloprodajni formati omogućuju brzo i jednostavno pokretanje novih poslovnica. Za mnoge vodeće banke razvijenih tržišta koje sada traže M & A mogućnosti na tržištima u nastajanju, lean može pružiti ogromne prednosti kada su u pitanju nova preuzimanja. Lean pruža mehanizam za banke kako bi se osiguralo da se najbolje prakse sustavno šire kroz sve njihove operacije.

Nadalje, postajanje jednostavnog lean “frameworka” za maloprodajni lanac, omogućava jednostavno širenje na nova geografska područja. Mnoge banke na nova područja pokušavaju ući kroz spajanje ili akviziciju postojećih lokalnih jedinica. Lean u tom slučaju jako olakšava njihovu inkorporaciju u postojeću mrežu. [4]

### **6.1.3 Primjer potencijala leana**

Oko 2.5 milijarde ljudi, većinom u Africi, Aziji, Južnoj Americi te na Bliskom Istoku nemaju pristup bankama niti financijskim uslugama. No potreba postoji. Istraživanje u Južnoj Africi pokazalo je da prosječno siromašnije kućanstvo koristi 17 različitih financijskih instrumenata kroz jednu godinu. Korištenje financijskih usluga sivih zona dolazi s cijenom. Recimo, kratke posudbe mogu imati kamate čak do 50%, u usporedbi s 14% do 16% koliko bi ista usluga koštala u banci.

Izazov za financijske institucije je pronaći poslovni model koji će s jedne strane biti profitabilan, a s druge zadovoljavati potrebe siromašnijih korisnika.

Kako bi to bile u stanju izvesti, potrebno je da drastično srežu troškove te usluge. Upravo zahvaljujući leanu mnoge banke na novim tržištima uspijevaju ponuditi usluge eliminirajući neefikasnosti i centralizirajući svoje procese. No ako uspiju dodatno sniziti cijenu svojih proizvoda te naći jednostavnije, povoljnije kanale distribucije vjerujem da će uspjeti popuniti i tu potrebu na tržištu koja još nije riješena. [4]

## 6.2 5 koraka vitke transformacije poduzeća

U dualnoj strategiji navedeno je 5 lean alata koja će optimizirati proizvodnju. Lean alata ima mnogo više, no navedeni su u cost-benefit omjeru najisplativiji. Lean je sam po sebi nepoznat pojam većini zaposlenika i zbog toga postoji određena odbojnost, strah od nepoznatog prilikom implementacije. Kako bi lean radionice mogle biti uspješno implementirane, nužno je imati motivirane sudionike. Bez kooperativnosti zaposlenika teško je uspješno uvesti lean.

Kako najbolje približiti nekome nepoznat, apstraktan pojam? Kako najbolje motivirati sudionike? Kako im na banalan način prikazati prednosti leana?

Jednostavim simulacijama.

Iz toga razloga, u ovom radu dualna strategija je nadograđena simulacijama leana. Proces vitke i digitalne transformacije započinje tim igrama to jest simulacijama. Lean igre olakšat će radnicima koji sudjeluju u lean transformaciji poimanje cjelokupnog procesa te im na jednostavnom i banalnom primjeru pokazati kakve napretke u produktivnosti mogu očekivati. Tako “razbijamo” negativne emocije i suzdržanost koje sudionici procesa mogu imati protiv promjena. U psihologiji taj proces naziva se “foot in the door”.

## 6.3 Foot in the door

Ranije je spomenuto kako mnoge tvrtke nisu još spremne na promjene, odgađaju ih, zadržavaju status quo zbog straha od nepoznatog. Nekada je teško komprehirati prednosti apstraktnih koncepata te je ih potrebno simplificirati kako bi postali razumljivi. Zato služe lean igre.

No naslov ovog poglavlja je “Foot in the door”.

Zašto?

Zato što lean simulacija može biti prvi korak prema kompletnoj vitkoj transformaciji.

“Foot in the door” je poznata psihološka tehnika koja pretpostavlja da će ljudi lakše pristati na nešto zahtjevnije, ako prethodno pristanu na neku manju molbu. Osnovno načela po kojem “foot in the door” funkcionira je konzistentnost. Ljudi vole biti konzistentni. [7]

Upravo na toj bazi možemo povući paralelu s lean igrom kao manjom molbom, manjom količinom uloženog truda, nakon čega će sudionici biti motiviraniji te jednostavnije prihvatiti veću molbu, odnosno cjelokupnu lean filozofiju.

## **6.4 Lean simulacije**

Postoje mnoge lean igre ili bolje rečeno simulacije, ima ih na desetke, no u ovom radu izvukao sam 3 koje smatram najreprezentativnijima.

Svaka igra ima neki cilj koji želi postići.

### ***6.4.1 Toranj od spaghetti***

Kratka simulacija koja prikazuje pogodnosti lean filozofije. Timski rad temeljac je uspjeha. Tim, kao živi organizam, mora biti u mogućnosti komunicirati, iterirati, napredovati i poboljšavati se. Jedan nekvalitetan član je kao neispravna karika u lancu. Kroz igru tim se upoznaje (ako je novo formiran) te se Belbinove uloge unutar tima formiraju.

Cilj je demonstrirati prednosti kvalitetnog timskog rada te prepoznati buduće lidere.

### ***Kako igrati?***

#### **1. OFORMITI TEAM**

Prvi korak je oformiti timove koji će sudjelovati u simulaciji. Svaki tim treba imati između 3 i 8 članova.

#### **2. PRIPREMITI PROSTOR**

Pripremiti broj stolova ovisno o broju timova. Na svaki stol treba staviti vrećicu špageta i 10tak marshmallowa. Marshmallowi služe kao cement, odnosno smjesa za povezivanje spaghetti, dok su špageti konstrukcijski materijal.




### 3.UPOZNATI SUDIONIKE SA ZADATKOM

Zadatak je složiti što višu konstrukciju, oblika po izboru, koja će moći na vrhu izdržati masu jednog marshmallowa. Ne postoji točno rješenje, tim koji najbolje radi zajedno te bude najviše kreativan pobjeđuje. Cilj je prepoznati potencijal grupe, leaderske karakteristike pojedinaca te podučiti pojedince u uspjeh grupe koja funkcionira homogeno.

### 4. SAMOEVALUACIJA

Nakon evaluacije rezultata i proglašenja pobjednika timove se pitaju sljedeća pitanja;

- Kako bi ocijenili vaš tim?
- Što ste mogli napraviti bolje?
- Na kakve ste prepreke naišli?

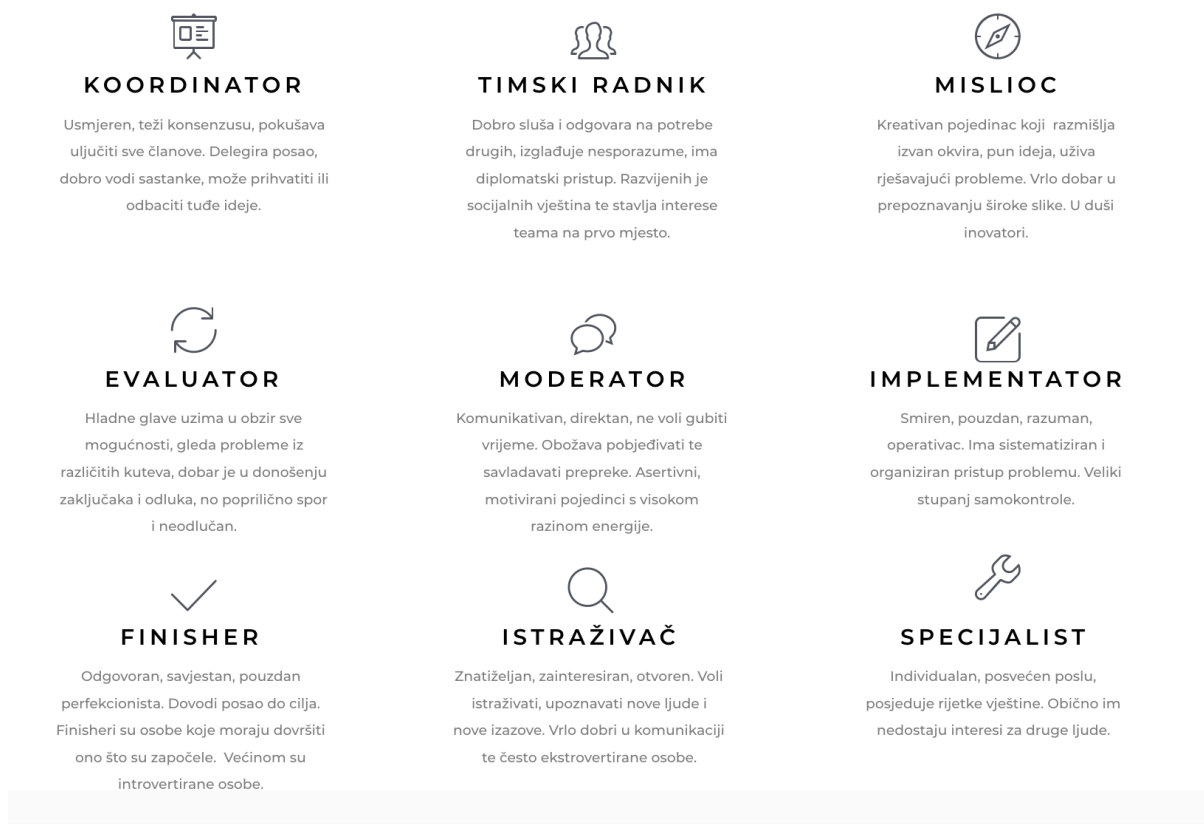


Slika 31. Primjer iz igre

Interesantni ishod ove simulacija je mogućnost prepoznavanje “Belbinovih uloga” u timu. [8]  
Dr. Belbin britanski je znanstvenik rođen 1926.godine te se smatra ocem teorije timskih uloga. Balbin smatra da pojedinci unutar tima imaju tendenciju preuzimati različite timske uloge. Imenovao je 9 takvih timskih uloga koje utječu na uspjeh.

Belbinova identifikacija uloga pokazala se korisnom u:

- procijeni pojedinca - povećanje svijesti o sebi i preferencijalnim ponašanjima. Pokazuje na radne zadatke koji najviše odgovaraju tom tipu osobe
- procijeni radnog mjesta - pruža jasno definirane zadatke, poželjne osobine i osobnosti koje osoba treba posjedovati
- procijeni tima - omogućava kvalitetnu selekciju članova tima, identifikaciju članova tima s najsnažnijim ulogama te razumijevanje jedinstvenih snaga među članovima tima



Slika 32. Belbinove uloge

### **6.4.2 Igra kovanicama**

Kratka simulacija koja prikazuje pogodnosti lean proizvodne trake. Vitka proizvodnja donosi veće zadovoljstvo kupcima, radnicima i menadžerima.

Kroz igru uočit ćete koliko je brže dostaviti kupcu proizvode te lakše raditi izmjene u toku ukoliko se pridržavate lean načela.

Cilj je demonstrirati prednosti vitke proizvodnje na brz i jednostavan način.

Potrebno je:

- 20 kovanica
- stolovi koji odgovaraju broju timova
- odgovarajući broj sjedećih mjesta/stolica

#### ***Kako igrati? [9]***

1. Nabaviti neku nagradu za pobjednički tim. Ne treba ništa vrijedno, može biti par slatkiša, služi kao dodatna inicijativa za participaciju.

2. Vidjeti koliko je sudionika. S obzirom na to formirati ravnomjerne timove. Najbolje je ako će u svakom timu biti po 3 osobe i team-menadžer (osoba koja će mjeriti vrijeme).

3. Nakon što svaki tim ima 3-5 članova + team menadžer treba im dati imena. Primjerice tim proizvodnja, tim R&D, tim nabava itd. Svaki menadžer treba imati štopericu, može se koristiti sat ili aplikacija na mobitelu.

4. Podijeliti svakom timu 20 kovanica te im reći da ih pripreme sve tako da ih okrenu na istu stranu.

5. Objasnite im pravila. Kovanice se mogu prebacivati s jedne na drugu poledinu samo jednom rukom s time da ruke smiju zamijeniti tijekom prebacivanja. Za dodavanje kovanica idućoj

osobi u timu smiju koristiti obje ruke. Vrijeme se zaustavlja tek kada su svi novčići predani kupcima.

6. Pripremiti flipboard na koji će se upisivati rezultati timova. U svakoj rundi (ima ih četiri) broje se dva vremena. Prvo vrijeme je ono potrebno da to kupca dođe prva kovanica, a drugo vrijeme ono do isporuke zadnje kovanice kupcu.

7. Prva runda započinje. Prvi sudionik u teamu mora prebaciti svih 20 kovanica s jedne na drugu, poštivajući ranije navedena pravila, tek nakon što je prebacio svih 20 predaje ih drugom članu tima. On također mora prebaciti svih 20 kovanica te ih potom proslijediti trećem članu tima. Treći član tima radi isti postupak te kada završi sa svih 20 isporučuje ih kupcu (mjesto desno od njega). Menadžer bilježi vrijeme potrebno prvoj kovanici i zadnjoj kovanici da dospije do kupca, u prvom krugu razlika između ta dva vremena biti će nezamjetna, možda sekundu, dvije. Rezultati se upisuju u tablicu za svaki team.

8. Dopustiti im da ponove prvu rundu i pokušaju ostvariti bolji rezultat pošto su se tek zagrijali.

9. Drugi krug započinje. Razlika u ovom krugu je da se ne odrađuje cijela serija (20 kovanica) prije slanja idućoj osobi, već dvije serije od 10 kovanica. Nakon što prvi član tima prebaci 10 kovanica mora ih proslijediti drugoj osobi, te potom dovršava ostalih 10 kovanica koje potom šalje idućoj osobi. Tako do kraja. Menadžer opet štopa 2 vremena. Prvo je ono potrebno prvoj kovanici da dođe do kupca, a drugo ono potrebno zadnjoj da dođe do kupca.

Rezultati se upisuju u tablicu za svaki team.

8. Treći krug započinje. Razlika u ovom krugu je da se odrađuju 4 serije po 5 kovanica. Nakon što prvi član tima prebaci 5 kovanica mora ih proslijediti drugoj osobi, te potom dovršava idućih 5 i tako do kraja. Menadžer opet štopa 2 vremena. Prvo je ono potrebno prvoj kovanici da dođe do kupca, a drugo ono potrebno zadnjoj da dođe do kupca.

Rezultati se upisuju u tablicu za svaki team.

9. Četvrti krug započinje. Razlika u ovom krugu je da je svaka kovanica svoja serija, odnosno nakon svake prebačene kovanice prosljeđuje se dalje. Menadžer opet štopa 2 vremena. Prvo je

ono potrebno prvoj kovanici da dođe do kupca, a drugo ono potrebno zadnjoj da dođe do kupca. Ovdje će razlika u početnom i završnom vremenu biti najveća. Treba naglasiti da se ne može u jednom potezu kovanica prebaciti i poslati dalje. Ta dva poteza trebaju jasno biti odvojena.

Rezultati se upisuju u tablicu za svaki team.

Uvijek treba dati posebne napomene za posljednji krug. Naglasiti im i više puta da ne mogu okretati novčić i slati dalje u jednom pokretu. Također, ako im prilikom simulacije novčić isklizne sa stola, trebaju ga dignuti i vratiti na stol, pogreška je na njima i oni je moraju ispraviti dok vrijeme ide. Vrlo brzo će uvidjeti važnost izreke “you must go slow to go fast”.

Tim s najkraćim vremenom osvaja nagradu.

11. Za kraj pitamo sudionike: “Zašto smo igrali ovu igru? Što nam brojevi kazuju?” te potom slijedi rasprava.



**Slika 33. Usporedbe vremena**

Na grafu se mogu vidjeti usporedbe rezultata kroz krugove. Vrijeme dolaska prve kovanice do kupca se očekivano smanjio, no zanimljivo je oučiti i pad vremena dolaska zadnje kovanice.

Kroz igru kovanicama sudionici će doći do brojnih zaključaka. Ona koja treba posebno isteknuti jesu da se dodatna vrijednost brže isporučuje, novi proizvodi brže razvijaju i modificiraju te se smanjio prazni hod.

### **6.4.3 Albatross**

Albatros je jedna vrlo zanimljiva simulacija vođenja sastanaka. Kroz jednostavnu simulaciju sudionici će uvidjeti koliko se vremena i energije na sastanci gubi na sporedne stvari te će postati samosvjesni toga. Rezultat su kvalitetniji, kraći i efikasniji sastanci.

U jednoj igri mogu sudjelovati 4 osobe.

Ako je više igrača, trebaju se organizirati u grupe od 4 osobe i fizički izolirati kako ne bi utjecali na međusobni rezultat. Svaki igrač igru može igrati samo jednom, nakon toga zna odgovore i nema više smisla ponavljati igru.

Igra se sastoji od 4 kruga, a svaki krug od 10 pitanja. Igrači dobivaju isprintana pitanja te samostalno odgovaraju na njih nakon što su pročitali tekst. Nakon što su svi odgovorili kreće sastanak. Svaki igrač bit će voditelj sastanka jedan krug.

Svoje samostalne odgovore stavljaju u lijevi gornji kut, dok odgovore grupe (nakon sastanka) u desni donji. Točni odgovori upisuju se u odgovarajuće polje. Na kraju se rezultati sumiraju i uspoređuju. [10]

Timski rezultati će u većini slučajeva biti točniji od grupnih. Također sudionici će uvidjeti koliko je fokus na sastancima bitan. Bit Kaizena je eliminirati neproduktivno vrijeme i sve gubitke.

Slijede upute za igru. Tekst je preveden s engleskoga kao i sva pitanja te prilagođen našem govornom području. [11]

*Jedan sveučilišni profesor iznajmio je brod u svrhu istraživanja. Kada je uočio veliku bijelu pticu, tražio je dopuštenje da je ubije. Rekao je da se albatrose može naći jedino na teritoriju obale Australije te da bi je htio kao izložbeni materijal za sveučilišni muzej.*

*Posada se protivila ubojstvu albatrosa te je podsjećala kapetana na kletvu koja kaže da loša sreća prati one koji love albatrose. Ipak, kapetan je dopustio profesoru da ubije pticu što je profesor potom i učinio.*

*Nakon ubojstva albatrosa dogodile su se sljedeće situacije.*

*Sidreni lanci zapetljali su se 3 puta.*

*Sidro je zapelo za dno te se u potpunosti raspalo.*

*Osovina na glavnom vitlu je popucala te je trebalo članovima posade 5 sati da ručno namotaju 1700 stopa lanca.*

*Profesorov asistent je pao s ljestvi te slomio rebro.*

*Po prvi puta u životu profesor je obolio od morske bolesti.*

*Zbog izgubljenog pogonskog zupčanika brod je morao krenuti prema luci.*

*Kuhar je dao otkaz.*

Sudionici odgovaraju na sljedećih 40 izjava označavajući u gornji lijevi kut:

- T - ukoliko smatrate tvrdnju točnom
- N - ukoliko smatrat tvrdnju netočnom
- ? - ukoliko smatrate da tekst ne sadrži dovoljno informacija za odgovoriti pouzdano

### **Bijeli albatros - PRVI KRUG**

Svom srećom, lanci se nisu zapetljali.	T	N	?
Profesorov asistent je slomio nogu.	T	N	?
Nakon što je ubijena ptica, počele su se događati nezgode.	T	N	P
Bijeli albatros je viđen u blizini obale Australije.	T	N	?
Problemi su se dogodili nakon ubojstva ptice.	T	N	?
Mornari nisu bili uznemireni nakon što je albatros ubijen.	T	N	?
Profesor nije iznajmio brod.	T	N	?
Profesoru je prineseno pozornosti da loša sreća slijedi nakon ubojstva albatrosa.	T	N	?
Kapetan je slomio rebro.	T	N	?

Dok su muškarci posade nesumnjivo bili uznemireni zbog radnji profesora, kuhar je bio jedini čovjek koji je napustio posao.	T	N	?
---	---	---	---

### Bijeli albatros - DRUGI KRUG

Priča izlistava razne nezgode koje su se dogodile nakon ubojstva ptice.	T	N	?
Profesor je pitao kapetana za dopuštenje smije li ubiti pticu.	T	N	?
Kuhar je otpušten zbog svojih prigovora na ubojstvo ptice.	T	N	P
Profesor je pitao za dopuštenje kada je vidio albatrosa da leti oko broda.	T	N	?
Brod, koji je bio upogonjen na motor, zapeo je u teškoće nakon što je zubčanik zagubljen.	T	N	?
1700 stopa lanca mornari su namotali ručno.	T	N	?
Profesorov asistent je slomio jedno rebro broda.	T	N	?
Profesor je očekivao da će vidjeti albatrosa.	T	N	?
Ptica je ubijena unatoč kapetanovoj zabrani.	T	N	?
Bijeli albatros je ubijen.	T	N	?



**Bijeli albatros - TREĆI KRUG**

Profesor nije bio sa sveučilišta.	T	N	?
Profesor je bio manje pod utjecajem klasičnih praznovjerja nego što su bili članovi posade.	T	N	?
Dopuštenje da se ubije ptica dao je kapetan.	T	N	P
Osoba koja je pala niz ljestve bio je profesorov asistent.	T	N	?
Profesor nije zatražio od posade dozvolu za ubojstvo albatrosa.	T	N	?
Prirodoslovac nije tražio dopuštenje da ubije pticu kako bi je osigurao za sveučilišni muzej.	T	N	?
Posada je prosvjedovala protiv ubijanja ptice.	T	N	?
Profesorov asistent je obolio od morske bolesti prije nego li je ptica ubijena.	T	N	?
Kuhar je pomogao prilikom namotavanja 1700 stopa lanca.	T	N	?
Profesor je pao niz stepenice.	T	N	?

**Bijeli albatros - ČETVRTI KRUG**

Nakon što je profesor upucao albatrosa, počele su se događati nevolje.	T	N	?
Profesorovo ime nije spomenuto.	T	N	?
Profesor je bio iznenađen kada je uočio albatrosa.	T	N	P
Zbog izgubljenog zubčanika brod se morao vratiti na zapadnu obalu.	T	N	?
Brod je bio iznajmljen od strane profesora.	T	N	?
Lanac se potrgao na dnu mora.	T	N	?
Vrsta ptice koja je bila ubijena je albatros.	T	N	?
Profesor nije htio pticu za sveučilišni muzej.	T	N	?
Kuhar nije napustio svoj posao.	T	N	?
Pticu je ubio profesor.	T	N	?

Nakon završetka igre sudionici odgovaraju na sljedeća pitanja i donose samostalne zaključke:

- Koji je bolji rezultat? Vaš osobni ili timski?
- Koja je vrijednost tima?
- Kako ste se osjećali vodeći sastanak?
- Kako biste ocijenili vašu neutralnost tijekom vođenja sastanka?
- Kako se možete poboljšati?

Sudionici će samo donesti zaključke te objeručke prihvatiti lean transformaciju jer smo im demonstrirali samo djelić promjena na bolje koji ih čekaju nakon promjene filozofije.

U ovoj fazi sudionici su uvidjeli prednosti leana kroz kratke simulacije. Entuzijizam je porastao i želja za educiranjem je veća. Može se krenuti na ozbiljnije alate.

Sljedeći korak je Kaizen.

## 6.5. Kaizen

Lean filozofija temelji se na ideji Kaizena - ili kontinuiranog poboljšanja. Ova filozofija podrazumijeva da male promjene koje se rutinski primjenjuju i održavaju tijekom dugog razdoblja, rezultiraju značajnim poboljšanjima. Kaizenova strategija ima za cilj uključiti radnike iz više različitih pozicija u organizaciju zajedničkog rada radi rješavanja problema ili poboljšanja procesa. Koriste se analitičke tehnike, kao što su mapiranje vrijednosti i "pet pitanja zašto", da brzo identificira mogućnosti za uklanjanje gubitaka u ciljanom procesu ili proizvodnom području. Cilj je da se brzo provedu odabrane promjene, kroz 72h koliko najčešće i traju radionice.

### 6.5.1 Primjena Kaizena [6]

Procesi kontinuiranog poboljšanja obično zahtijevaju organizaciju da potiče kulturu u kojoj radnici imaju slobodu rješavanja problema izvan striktno propisanih okvira. Većina organizacija koje provode lean procese poboljšanja utvrdili su metode i pravila koja su dobro shvaćena među zaposlenicima.

Kaizen proces sastoji se od sljedećih koraka:

1. Planiranje
2. Provedba
3. Naknadno praćenje

Prvi je izazov identificiranje područja koje želimo poboljšati. Takva područja mogu uključivati područja gdje se odrađuje najintenzivniji dio posla; administrativni proces, uska grla u proizvodnji, područja s najvišom razinom grešaka/škarta, područja s najnižom kvalitetom, područja koji pridonose najviše dodane vrijednosti konačnom proizvodu...

Nakon što je odabrano područje koje se želi poboljšati, slijedi korak odabira koji problem odnosno gubitak želimo reducirati u toj kaizen radionici. Tu se misli na specifični problem, poput ukupnog vremena proizvodnje, kvalitete ili produktivnosti. Nakon odabira problema menadžeri slažu team od zaposlenika različitih funkcija.

Važno je da timovi uključuju zaposlenike iz odabranog procesnog područja, iako je ponekad dobro uključiti “svježu krv”. Članovi tima prethodno bi trebali biti upoznati s osnovama lean filozofije. Upravo zato Kaizen radionice se obično organiziraju u trajanju od jednog do sedam dana, ovisno što i kako se želi postići.

Članove operativnog kaizen tima treba se osloboditi svakodnevnog posla za vrijeme trajanja radionice kako bi se mogli usredotočiti maksimalno.

U drugoj fazi, odnosno provedbi, tim prvenstveno radi na razvijanju jasne predodžbe problema ispred njih. Obično se koriste dvije tehnike za definiranje trenutnog stanja i prepoznavanje gubitaka:

- 5 pitanja zašto
- tok praćenja vrijednosti

5-zašto jednostavan je, ali vrlo moćan lean alat čija aplikacija vrlo široka. Sva mudrost iza metode je postavljanje pitanja zašto i ponavljanje 5 puta kako bi se ušlo u srž problema.

Kreće se od početnog problema, no svakim ponavljanjem uklanjamo jedan simptom i ulazimo sve dublje i dublje. Zna se pokazati da solucija konačnog problema ustvari nema veze s početnim pitanjem.

Što se tiče toka praćenja vrijednosti, ta metoda uključuje skiciranje toka aktivnosti, tokova materijala, komunikacija i drugih elemenata koji su uključeni u proces. Mapiranje tokova vrijednosti pomaže organizaciji da prepozna elemente koji ne dodaju nikakvu vrijednost u ciljani proces te da ih potom eliminiraju. U nekim slučajevima, praćenje toka vrijednosti može se koristiti u početnoj fazi kako bi se identificirale područja na koje će se primijeniti Kaizen metoda.

Za vrijeme provedbe Kaizena, potrebno je prikupiti informacije o procesu, kao što su kvaliteta proizvoda, količina otpada i neiskorištenih materijala, tijekom proizvodnje, ukupna udaljenost koju proizvod treba proći za vrijeme proizvodnje, ukupno kvadratura koju zauzima oprema, broj izmjena alata, broj uskih grla te raspored osoblja. Svaki član tima dobiva svoj zadatak za istraživanje i analizu.

Nakon prikupljanja svih potrebnih podataka, vrši se analiza se i pronalaze mjesta za napredak. Članovi tima prolaze proces po proces te se pitaju koliko pridonosi konačnoj vrijednosti. Kada članovi tima prepoznaju proces koji se može kvalificirati kao gubitak slijedi razmatranje ideja oko poboljšanja. Prijedlozi su često testirani te oni odabrani bivaju implementirani u proces. Odabrane su i implementirane ideje koje se smatraju najzahtjevnijima. Uspoređuje se prvotni i unaprijeđeni proces te mjere razlike.

Slijedi treća faza, odnosno praćenje. Nakon kaizen radionice, članovi tima rutinski prate ključne metrike kako bi dokumentirali poboljšanja. Nadzor se često ponavlja nakon 30 i 90 dana od radionice kako bi se uvidjela kontinuiranost. Svi rezultati bilježe se na vidljiva mjesta kako bi bila uočljiva svima uključenima u taj sektor.

## 6.6 5S

5S je jedan od najjednostavnijih, ali ujedno i najmoćnijih lean alata. Preduvjet je svih uspješnih unapređenja u proizvodnji, kao i preduvjet uspješnog procesa stalnih poboljšanja koje lean metodama težimo postići. Bez 5S nema niti SMEDA niti VMSa.

Sistem je uređivanja radnog mjesta po načelima što veće efikasnosti. Cilj je olakšati vidljivost, povećati praktičnost rada i smanjiti gubitke u vremenu.

U osnovi svake organizacije proizvodnje možemo naći pokušaj usavršavanja radnog mjesta i radnog okruženja, pripremu za proizvodnju, ergonomičnost i učinkovitost. Nameće se potreba za uređenjem i održavanjem radnog mjesta i okruženja urednim, čistim i ugodnim za rad. Prvotno je potrebno uložiti trud kako bi to postigli, a i kada se postigne, podložno je promjenama te teži, kao i svaki sustav u prirodi neurednosti, pretrpanosti, neorganiziranosti, a sve to rezultira manje učinkovitim radom i smanjenjem kvalitete proizvoda i procesa.

Koncept korijene vuče iz Toyote gdje je korišten za poboljšanje načina i uvjeta rada u pogonu.

5S metodologija ima za cilj ukloniti nepotrebne predmete sa i oko radnog mjesta koji usporavaju i otežavaju rad na uštrb efikasnosti. Također uvode se i upute što se, kako i kada radi te koja su zaduženja zaposlenika prilikom započinjanja smjene, ali i što moraju obaviti nakon završetka smjene. Sve je propisano.

5S se sastoji od 5 koraka:

- SEIRI - sortiranje
- SEITON - slaganje

- SEISO - spremanje
- SEKETSU - standardiziranje
- SHITSUKE - samodisciplina

Svaka riječ izvorno počinje sa slovom “s” po čemu je i 5S dobio naziv. Prve tri faze su upute za postizanje novog izgleda radnog mjesta i okruženja, dok posljednje dvije faze služe za održanje postignutog. U praksi, posljednje dvije faze su zahtjevnije. Nakon uspješnog provođenja 5S na radnim mjestima u pogonima, ako radnici nisu dovoljno educirani ili ne poštuju pravila održavanja, nivo kvalitete i urednosti će s vremenom padati. Zato je vrlo bitno stihijski raditi “auditing” odnosno nadzor stupnja održavanja radnog mjesta po propisanim pravilima kako bi se kvaliteta održala i 5S postao svakodnevna navika radnika. [53]




Slika 34. Radno mjesto prije i poslije provedbe 5S

## 6.6 VSM

Value stream mapping (VSM) u prijevodu na hrvatski znači mapiranje toka vrijednosti. Alat je koji omogućuje prikaz toka procesa od dobavljača do kupca, kategorizirajući procese na one koji dodaju vrijednost, one koji ne pridonose vrijednosti, mjesta gdje se događaju greške te prepoznavanje uskih grla. VSM predstavlja pogled iz ptičje perspektive na cijelo poduzeće. Nakon mapiranja, puno je lakše prepoznati u kojem smjeru krenuti dalje te gdje su najpotrebnije optimizacije. Možda proces koji smatramo uskim grlom uopće nije problematičan. Mapiranjem toka vrijednost kreiramo trenutčan presjek poduzeća. Na bazi

postojećeg, tim koji provodi lean transformaciju konstruira idealni tok vrijednosti koji potom služi kao model. [55]



Slika 35. Primjer VSM mape [56]

## 6.7 Standardizacija

Za razliku od Kaizena, 5S i VSMa standardizacija nije samostalan lean alat već pojam koji obuhvaća sve promjene koje služe uspostavi jasnih poslovnih procedura. Na početku rada, pod Industrijom 4.0 spomenuo sam da su poslodavci u anketi standardizaciju prepoznali kao najveći izazov digitalne transformacije.

Uvijek se prvo kreće od ljudi. Standardizacija posla, procedura i administracije. No problem kreće primjerice u proizvodnji gdje u jednom pogonu imamo 30 tokarskih strojeva, od 5

različitih proizvođača. Svaki proizvođač ima specifične ulaze, drugačije upute i procedure. Radnik koji radi na stroju proizvođača Puma možda se nikad nije susreo s Lynxom. Kada dođe do situacija da će trebati, morat će proći kroz krivulju učenja te neće biti jednako produktivan niti efikasan. Postotak škarta porasti će. Može doći do problema s cijelom serijom u toj smjeni. Rješenje je standardizacija.

## 6.8 Kvaliteta

Kontrola kvalitete brzo je rastući sektor. U vrijeme kada je konkurencija nikad jača, tržište sve zahtjevnije, a kupci imaju sve širi izbor proizvoda, kvaliteta je faktor broj jedan konkurentnosti.

U kontekstu dualne transformacije, podrazumijeva se[57]:

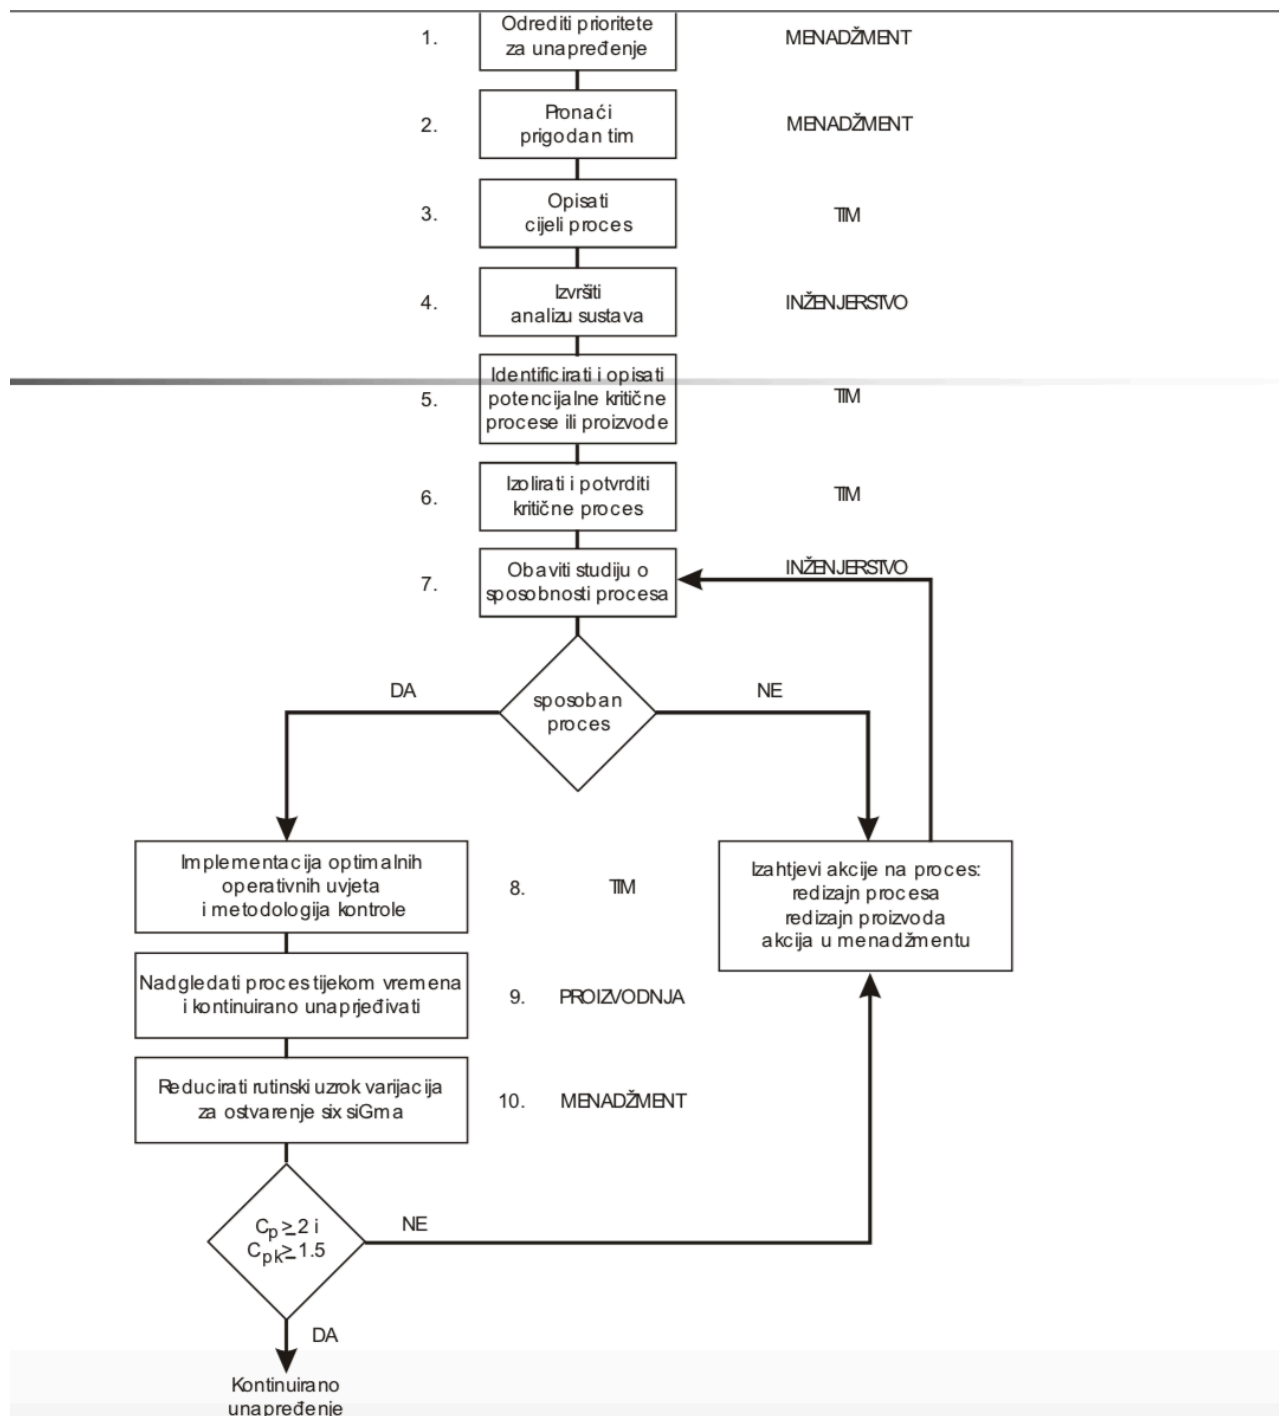
- kontinuirani fokus na kvalitetu proizvoda i usluga
- Six sigma (Šest sigma)
- kvaliteta ugrađena u procese
- Poka Yoke

Six sigma pojam prva je asocijacija kad se radi o kvaliteti. Riječ je o metodi koju je 1987. godine predstavila firma “Motorola” kao svoj program kvalitete, a razvio ju je Mikel J. Harry. Temelji se na poboljšanju kvalitete tako da se smanjuje rasipanje te tako pomaže da organizacije funkcioniraju bolje, brže i ekonomičnije. Pomaže poduzećima u postizanju više kvalitete kroz pronalaženje i uklanjanje uzroka nastalih grešaka u procesima. Poduzeće je potrebno raščlaniti do razine procesa gdje se oni uzorkovaju i analiziraju. Potom se djeluje ciljano na one s potencijalom za poboljšavanje. [58]

Koriste se dvije metode:

- DMAIC (definiraj, mjeri, analiziraj, poboljšaj, kontroliraj)
- DMADV (definiraj, mjeri, analiziraj, oblikuj, provjeri)






Slika 36. Six sigma implementacija [58]

## 7.7 koraka digitalne transformacije poduzeća

Ranije je spomenuto sedam integralnih koraka digitalne transformacija poduzeća kao dio dualne transformacije. U ovom radu odabrana je integracije IoT na tokarskom stroju o kojoj će kasnije biti više riječi.

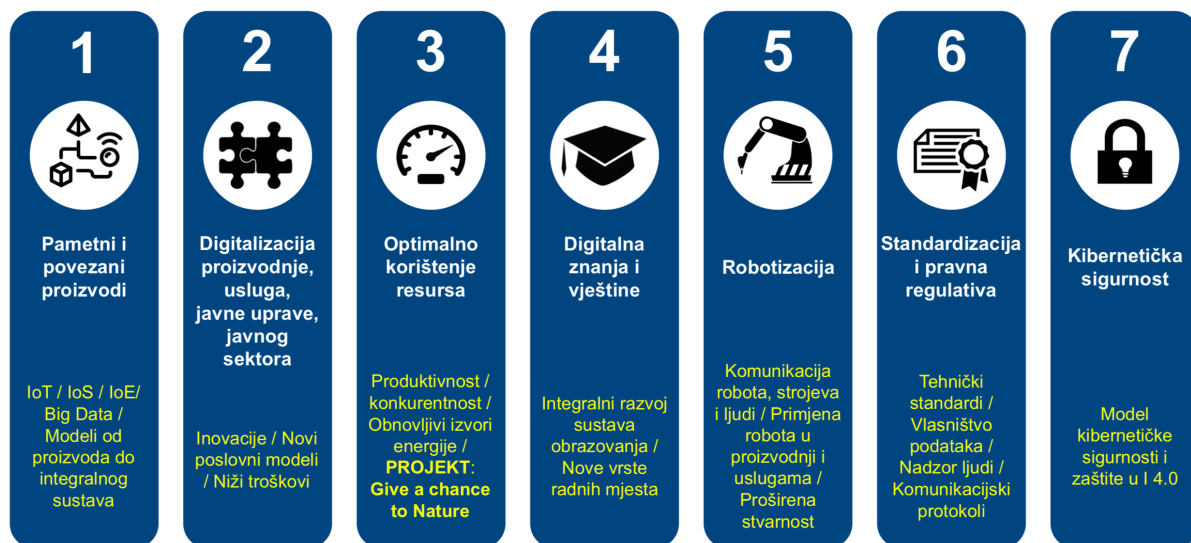
Na primjeru sljedeće slike vidljiv je proces umreživanja procesa.

Najniži novi je samostalni proizvod odnosno proces. Njihovim umrežavanjem dobivamo pametni proizvod. Na primjeru tokarilice, pametnu tokarilice. Njihovom međusobnom integracijom dobivamo povezani sustav. Integracija se vrši na zajedničkom hubu gdje više nema potrebe za fizičkim obilaskom stroja već je dovoljno imati dežurnog informatičara koji sve parametre može pratiti iz udobnosti ureda. Dapače, svake promjene uočljive su u stvarnom vremenu. U većini tvornica najviši nivo koji se može postići je treći.



Slika 37. Umrežavanje internet stvari [57]

Što se tiče ostalih 6 procesa o njima je rečeno već ranije u poglavlju glavnih tehnologija Industrije 4.0.



©N. Štefani

Slika 38. 7 koraka digitalizacije [57]

## 8. Primjena sustava vitke i digitalne transformacije u Feroimpexu

### 8.1. O poduzeću [59]

Poduzeće Feroimpex - Automobilska tehnika, nastalo je 1976. godine kao mala, kućna bravarska radionica koja se bavila proizvodnjom vijaka i opruga. Taj je mali pogon tijekom godina prerastao u radionicu za proizvodnju dijelova za strojeve za tekstilnu industriju. Danas je Feroimpex moderno poduzeće, koje djeluje na hrvatskom, europskom tržištu, ali i svjetskom tržištu. S više od 400 zaposlenih i prihodima od 30 milijuna eura uspješno konkurrira na zahtjevnom tržištu. Prvenstveno se bave proizvodnjom ležajeva, dijelova za automobilsku i željezničku industriju, proizvodnjom alata i komponenta ležajeva za vjetroelektrane. Proizvodnja ležajeva i opreme za automobilsku industriju čini 70% prodaje. Godišnje obrade 20 000 tona čelika i proizvedu oko 15 milijuna raznih dijelova za autoindustriju. 7500 tona čelika prođe kroz toplinsku obradu. Proizvodni pogoni nalaze se na Jankomiru u Zagrebu te zauzimaju preko 12 000 metara kvadratnih. Poduzeće je u 100% privatnom vlasništvu obitelji Legac. Osvojili su 2 zlatne kune, 2011. i 2015. godine, 3 zlatna ključa za izvoznika godine te je Habiba Legac 2015. godine proglašena poduzetnikom godine u kategoriji izvoznika pod organizacijom E&Y.



Slika 39. FAT

2013. godine dobili su jamstva Hrvatske agencije za malo gospodarstvo i investicije (Hamag Invest) za kreditiranje novog pogona. Radilo se o investicije vrijednoj 31 milijun kuna, od čega se kreditom pokrilo 23 milijuna. Hamag je dao jamstvo od 11.5 milijuna kuna, najveći iznos garancije te agencije do tada. Investicija je bila namjenjena za gradnju nove peći za toplinsku obradu komponenti ležajeva koja je u međuvremenu 2015. godine puštena u pogon. [60]

U 2018.g u suradnji s Fakultetom strojarstva i brodogradnje započeli su projekt “Hrvatska inovativna rješenja za globalnu automobilsku industriju” težak 54 milijuna kuna. [61] Projekt je odobren od strane Ministarstva gospodarstva, poduzetništva i obrta, u sklopu natječaja “Povećanje razvoja novih proizvoda i usluga koji proizlaze iz aktivnosti istraživanja i razvoja” iz Europskog fonda za regionalni razvoj, odnosno iz njegovog operativnog programa Konkurentnost i kohezija. Projekt traje 3 godine te mu je cilj povećati konkurentnost tvrtke uz znatne uštede. Podijeljen je na 3 dijela:

- inovativno rješenje za lomljenje metalne strugotine
- inovativno mjerenje
- automatizacija i digitalizacija proizvodnje.



**Slika 40. Proizvodna hala**

## 8.2 Proizvodni pogon

Feroimpex ima 4 pogona. Pogon se sastoji od više segmenata. Radnik u svojoj smjeni većinom vrijeme provodi na glodalici ili tokarilici te surađuje s inženjerima iz kontrole kvalitete.

Proizvodni pogon dijeli se na:

- obrađivanje tokarenjem
- obrađivanje glodanjem
- kontrolu kvalitete
- alatnicu
- toplinsku obradu



Slika 41. Alatnica

## 8.3 Proizvodi



Slika 42. Proizvodi



Glavni proizvod Feroimpex automobilske tehnike je ležaj za automobilsku industriju. No ne i jedini. Proizvode i zubčanike, kućišta te alate za vlastitu upotrebu. Kontrolne urice, elemente za provjeru dimenzija tijekom proizvodnje, kojih ima oko 2500, rade sami za svoje potrebe.

### **5.3 Alatnica**

Alatnica je sastavni dio proizvodnog pogona. Skladište je za pakne, prstene i stezne glave. Dijelove koji su nužni za operativni, svakodnevni rad tvornice. U vrlo je dobrom stanju ako uspoređujemo sa sličnim poduzećima industrije. Alati su pedantno orhanizirani po policama te grupirani ovisno na kojoj se proizvodnoj liniji najčešće koriste. Što se urednosti i čistoće tiče, pazi se na stanje u alatnici te su radnici upoznati s osnovnim elementima 5S održavanja prostora. S obzirom da je alatnica relativno mala i skućena, urednost i sistematičnost je prijeko potrebna.

### **8.4 Odabir procesa**

Tema diplomskog rada je vitka i digitalna transformacija poduzeća. Po pravilima struke, takav bi projekt transformacije trajao oko 3 godine. S obzirom da je vrijeme dostupno za diplomski puno kraće odabran je proces mjerenja na kontrolnim uricama te na njima primijenjen Kaizen alat (vitka transformacija, standardizacija) te na primjeru tokarilice uvedeno senzorsko mjerenje vremena te automatsko dizanje u “cloud” kao primjer implementacije IoT.

### **8.5 Problem kontrolnih urica**

Kontrolne urice predstavljaju jedan od ključnih faza u proizvodnji ležajeva. U automobilske industriji metalni obradak (u slučaju Feroimpex AT, najčešće ležaj) može imati do 15 različitih dimenzija te zahtijeva 100% točnost u svim dimenzijama. Automobilska industrija poznata je kao jedna od najzahtjevnijih i konkurentnijih.

U slučaju pogreške i proizvodnje škarta može doći do:

- povlačenja cijele serije

- financijskih gubitaka
- loše reputacije tvrtke

Trenutno se mjerenje provodi na svakom radnom mjestu korištenjem do 15 interno razvijenih mjernih uređaja te se ručno bilježi u sustav. Nakon zaprimanja novog naloga te podešavanja stroja, radnik započinje proizvodnju prvom komada. Potom ga mjeri na kontrolnim uricama na radnom mjestu. Ovisno o potrebama proizvoda, to može biti od 5 do 15 dimenzija. Ako jedna od njih nije dobra, ponavlja postupak. Ponovno podešava stroj i pušta sljedeći komad. Provjerava ga na uricama. Postupak se ponavlja dok god ne prođe provjeru svih dimenzija. No ni onda se serija ne pušta u proizvodnju. Slijedi provjera tog izradka u kontroli kvalitete. Radnik nosi izradak u kontrolu kvalitete gdje se vrši elektronička kontrola. Ako tamo ne dobije pozitivnu ocjenu cijeli postupak se ponavlja isponova. Ako prođe kroz kontrolu kvalitete, radnik dobiva zeleno svjetlo te se započinje proizvodnja serije. Svejedno, radnik tijekom trajanja serijske proizvodnje mora na kontrolnim uricama provjeriti svaki treći obradak jer tijekom izrade može doći do trošenja tokarskog noža i grešaka. Zbog povjerljivosti podataka nije moguće detaljnije ući u postupak, no kao što se vidi, cjelokupni proces mjerenja dugotrajan je i ovisi o ljudskom faktoru. Ljudski faktor najčešće je i izvor grešaka.

Kada sumiramo, problemi trenutne solucije su:

- usko grlo
- sporo
- ljudski faktor greške
- potrebni dodatni radnici

Prije početka Kaizen radionice demonstrirane su 3 lean simulacije kako bi timu odabranom od strane Feroimpexa apstraktni proces leana postao jasniji.



**Slika 43. Kontrolne urice**

Rezultati prve igre pokazali koliki produktivnost raste. Lean smanjuje serije i na taj način omogućuje veću fleksibilnost i produktivnost radnika. Smanjuje se čekanje između procesa. Čekanje je jedan od gubitaka koji ne pridonose dodatnu vrijednost te je vrlo česta pojava u proizvodnim pogonima. U drugoj simulaciji, tornju od špageta treniran je timski rad. Bit tima je da je sinergija sposobnosti tima veća od zbroya pojedinačnog članova tima. Team mora sam po sebi pojačavati radnika. Simulacija je to pokazala. Dapače, čak i na tom kratkom uzorku od pola sata polako su se krenuli ocrtavati obrisi Belbinovih uloga tima po sudionicima. Dalo se prepoznati tko ima liderskih kapaciteta, a tko će biti dobar operativac. Treća igra, Albatros, upravo je usmjerena prema vođenju sastanaka. Brojna istraživanja pokazala su sastanke kao izvor neproduktivnih sati rada. Vrlo rijetko osoba koja vodi sastanak zna spriječiti distrakcije. Sastanci odu u krivom smjeru. Potroše se minute i minute na semantiku ili detalje na koje uopće sudionici ne mogu utjecati niti bi trebali. Albatros demonstrira upravo to. Koliko je bitno sastanak formalizirati, usmjeriti i voditi prema određenom cilju.

## 8.6 Kaizen radionica

S fakulteta odabrane su dvije osobe da sudjeluju u Kaizen radionici. Feroimpex je za sudjelovanje u simulaciji i radionici odabrao 4 osobe, 2 operatera i 2 voditelja pogona. Nakon kratkog uvoda u lean i digitalizaciju započeli smo sa simulacijama. Simulacije su vidno postigle svoj učinak te podigle entuzijazam u sudionicima. Bili su spremni za radionicu.

Radionica započinje zapisivanjem teme na ploču. Tema je bila kontrolne urice.

Postavljaju se iduća pitanja te dolazi do izmjene ideja:

- Kako teče proces mjerenja?
- Koji su vam najveći izazovi kod toga?
- Imate li ikada kakvih problema i koji su to?
- Kada bi mogli bilo što promijeniti u tom procesu što bi to bilo?
- Kako odabirete urice?
- Kako umjeravate urice?
- Što vas smeta na uricama?
- Mogu li urice biti napravljene bolje?
- Čime bi zamijenili urice?



3 su osnovna elementa procesa rješavanja problema. Prvo treba identificirati problem, zatim ga jasno objasniti te potom prepoznati uzrok. [62] Najlakši način za prepoznati uzrok je pomoću metode 5- Zašto. 5-zašto jednostavan je, ali vrlo moćan Kaizen alat čija je primjena vrlo široka. Sva mudrost iza metode je postavljanje pitanja zašto i ponavljanje 5 puta kako bi se ušlo u srž problema.

Kreće se od početnog problema, no svakim ponavljanjem uklanjamo jedan simptom i ulazimo sve dublje i dublje u srž problema. Često se pokaže da rješenje konačnog problema ustvari nema veze s početnim pitanjem. Metoda se odvija u 4 koraka. Prvo se zapiše specifični problem. Zatim se tim zapita “Zašto dolazi do toga? Zašto se događa?”. Ukoliko taj odgovor ne rješava izvor problema iz prve točke zapitati se ponovno isto te zapisati odgovore. Kružni proces ponavlja se dok se ne dođe do solucije.

Može se reći da je rasprava otišla u dva smjera. Jedan je kako ustoličiti najbolju praksu i standardizirati proces mjerenja na postojećim uricama. Drugi je prema kompletnoj automatizaciji i zamjeni postojeće metode.

Najbolja praksa značila bi napisati upute na koju dimenziju narihtavanja posebno pripaziti kod svakog proizvoda. Generalno svaki obradak ima jednu plohu koja je kritična i koja najčešće zadaje komplikacije. Kada bi jasno bilo ispisano koja je to ubrzao bi se proces. Radnik koji završava smjenu trebao bi pripremiti mjerne urice, po uputama koji se projekt idući proizvodi za sljedeću smjenu na radnom mjestu. Trebalo bi se češće kontrolirati mjerne urice i na vrijeme zamijeniti stare novima kako ne bi došlo do nepotrebnih čekanja. Napraviti kratku edukaciju za nove radnike s najboljim praksama kako ne bi trebali učiti na svojim greškama. Napraviti priručnik korak po korak koji će podsjećati svakog radnika u smjeni kako postupati s mjernim uricama.

Drugi smjer išao je prema kompletnoj automatizaciji. Radnicima je jasno kako su najčešće greške one ljudskog faktora i kako bi se ovaj korak u toku vrijednosti mogao automatizirati. Već je i ranije bilo prijedloga da se trenutna solucija zamjeni s kutijom koja bi bila programabilna koje dimenzije mjeriti te kroz koju bi svaki obradak trebao proći. Tako, umjesto svakog trećeg, kontrolirao bi se svaki izradak. Kontrola i sljedivost bila bi 100%tna. Međuostalom, upravo je dio ranije spomenutog projekta “Inovativna hrvatska rješenja za globalnu automobilsku industriju” i osmišljavanje novog inovativnog načina mjerenja.

## 8.7 Digitalizacija tokarilice

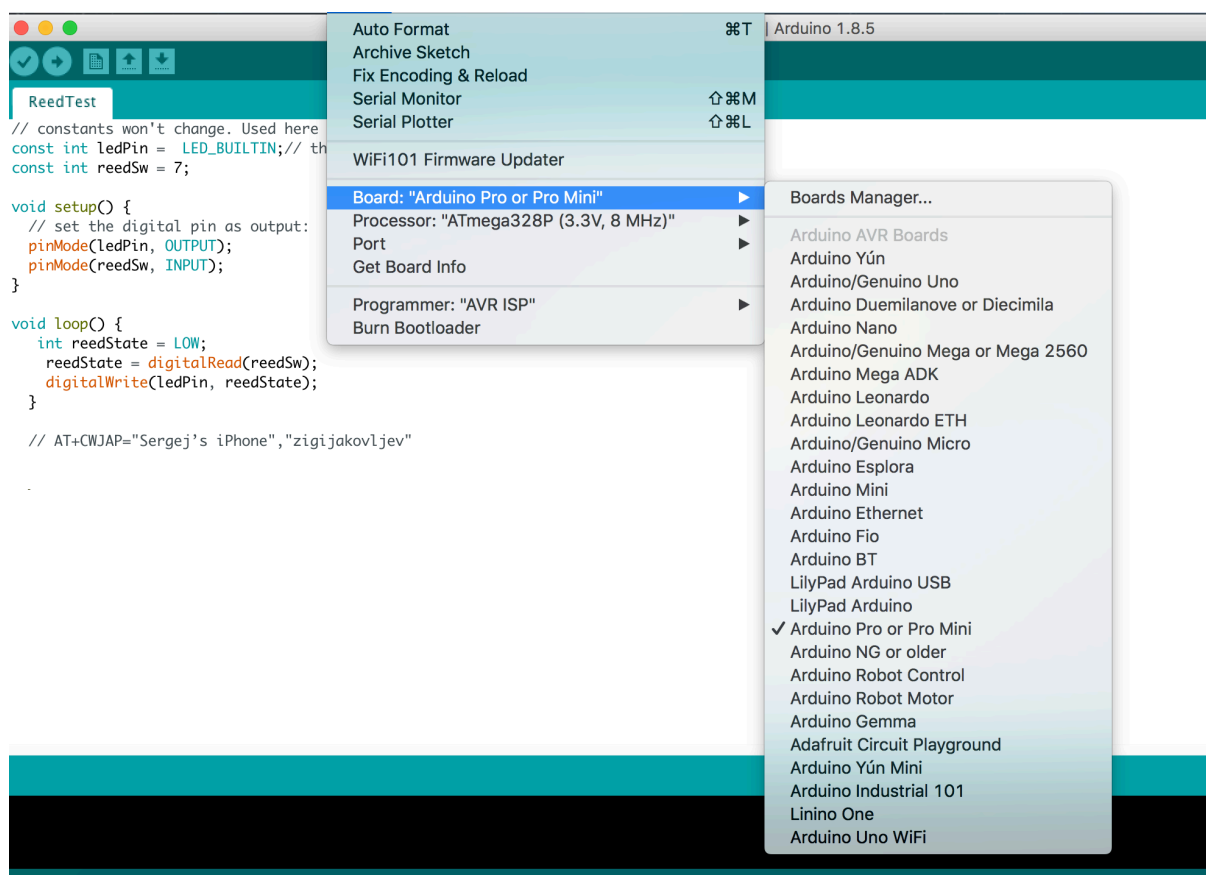
Odabran je proces digitalizacije tokarilice. U kontekstu digitalizacije misli se na ugradnju pametnih senzora i transformaciju u pametnu tokarilicu. Svaka operacija na tokarilici ima svoje normirano vrijeme. Ono je nešto dulje nego što u praksi taj proces traje. Svaka proizvodna linija sačinjena je od dvije tokarilice te dvije operacije. Radnik stavlja obradak u prvu, zatim ide prva operacija obrade. Potom vadi iz te tokarilice, propuhuje te stavlja u drugu tokarilicu gdje započinje druga operacija. Nakon druge operacije, radnik propuhuje obradak te mjeri dimenzije na kontrolnim uricama. Vrijeme manipulacije obradkom ima velike varijacije ovisno o kvaliteti i iskustvu radnika. Ne postoji neki sustav gdje se vremena bilježe kako bi se mogle raditi analize i poboljšanja. Odlučeno je da se na tokarilice stave magnetski senzori koji će bilježiti točno vrijeme otvaranja vrata te na bazi tih podataka mjeriti vrijeme manipulacije.



Slika 44. Puma 2600 [66]

Tokarilica na kojem je provedena digitalizacije je Puma 2600.


Kao baza korišten je Arduino open source hardver. Open source znači da je njegova shema dostupna svakome na uvid i svatko ga može proizvesti na nekoliko načina. Arduino postoji u različitim verzijama te je moguće pronaći različite mikrokontrolere kao što su Intel® Curie, ATtiny85, ATmega168V, ATmega328P, ATmega32U4, ATmega2560, SAMD21 Cortex-M0+, ATSAM21G18, ATSAM3X8E, AR9331 Linux ili SAMD21 Cortex-M0+ 32bit ARM MCU.



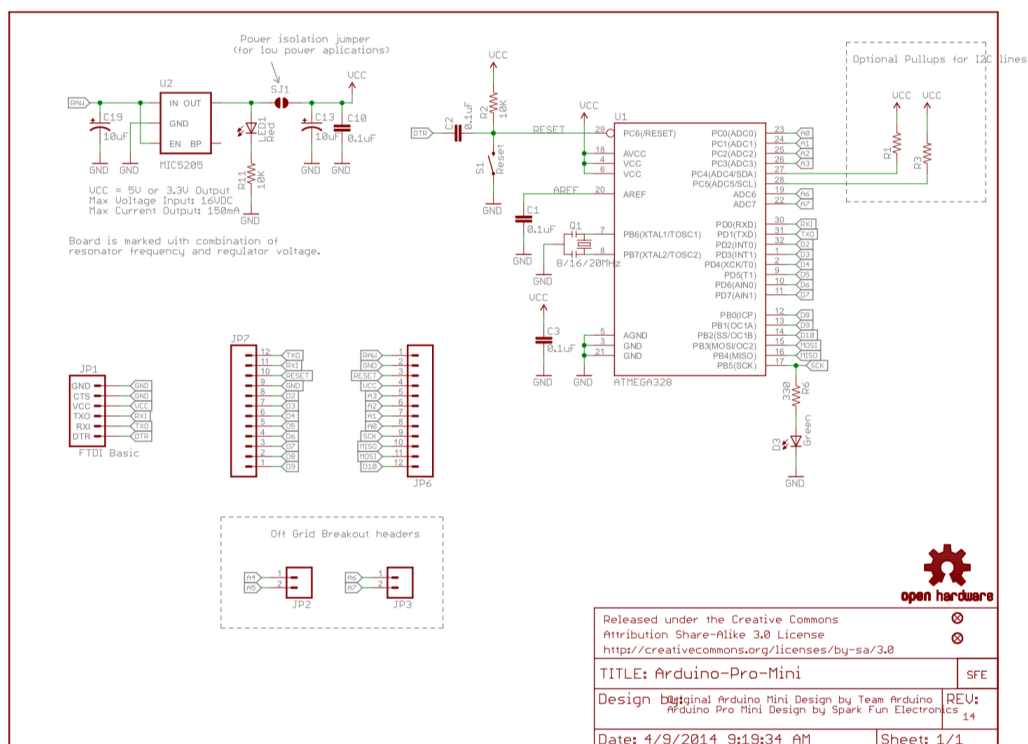
**Slika 45. Podešavanje Arduina**

U ovom slučaju korišten je Arduino Pro mini koji koristi ATmega328P mikrokontroler koji radi na 8 MHz, 2 kB RAM-a te 12 digitalnih ulazno-izlaznih pinova i 4 pinova za ulaz analognih podataka. Pro mini radi na napajanju od 3 V kroz USB ili se može napajati posebno preko napajanja. Glavna razlika između najpopularnijeg Arduina Uno i Pro mini je u njihovoj veličini i u broju ulaza. Kao što se vidi na slici Arduino Pro mini nema integrirani ulaz za USB i spajanje na računalo. Potrebno je bilo kupiti USB-to-serial konverter pod nazivom FTDI.

Nakon lemljenja pinova i spajanja FTDI na Arduino Pro mini moglo se krenuti za programiranjem.



Slika 46. FTDI [71]




Slika 47. Arduino Pro mini shema [72]

Za upravljanje Arduinoom koristi se Arduino GUI. Prvo je u postavkama trebalo podesiti model.

Board: Arduino Pro or Pro Mini

Procesor: ATmega328P (3.3V, 8MHz)

Uz Arduino, za funkcioniranje idejnog rješenja bili su potrebni magnetski REED senzori koji služe za očitavanje trenutka zatvaranja vrata tokarilice. REED senzor spojen je na Arduino te stavljen na fiksni dio tokarilice. Na mobilni dio vrata stavljen je mali magnetiće. Kada su vrata zatvorena udaljenost senzora i magneta je pola centimetra, dovoljno blizu da se signal očitava. Arduino je isprogramiran tako da se na internu memoriju sprema trenutak kada se vrata zatvore. REED switch funkcionira tako da se prekine strujni krug kada se izgubi kontakt između senzora i magneta. Za razliku od “limit switcha” koji je jeftinija alternativa, ali ga je teže u praksi primijeniti jer vrata trebaju kliknuti. Stoga bi trebao biti u fizičkom kontaktu.



**Slika 48. REED switch [63]**



**Slika 49. Limit switch [64]**

No sada je taj pametni, jednostavni sustav trebalo i spojiti na internet kako bismo dobili IoT. Kako je to napravljeno?

Spajanjem ESP8266 pločice. ESP8266 je wifi mikrokontroler koji se spaja na Arduino te omogućuje njegovo povezivanje na internet. Kao platforma na koje se podižu informaciju korišten je privatni server. U praksi, koristio bi se ThinkSpeak kao jednostavnija alternativa.[69]

Nakon određenih problema tehničke karakteristike, uz pomoć kolega koji se bave robotikom uspješno je postignuto traženo rješenje.

REED senzori ugrađeni su na vrata tokarskog stroja, ESP8266 senzor spojen na internet te je informatičar mogao u bilo kojem trenutku iz bilo kojeg kutka svijeta provjeriti vrijeme na tome stroju. Pilot program na procesu tokarenja pokazao je na koji način je moguće digitalizirati proces uzorkovanja i mjerenja tekućih vremena u proizvodnji. Sada se za svaku operaciju može u praksi izmjeriti, a potom i aproksimirati prosječno vrijeme potrebno za obradu i za manipulaciju obratkom koje obavlja radnik.

## KOD

```
#include <SoftwareSerial.h>

#define REED_0_PIN 6
#define REED_1_PIN 7

#define RX 10
#define TX 11

SoftwareSerial esp8266(RX,TX);

String AP = "Petar's iPhone";
String PASS = "wifi00000";

#define DATA_POINTS 50

const short UPLOAD_INTERVAL = 12; // sec.
const short RESOLUTION = 10; // measurements/sec
const short SLEEP_INTERVAL = 1000 / RESOLUTION;

void setup() {
```

```
Serial.begin(9600);
esp8266.begin(9600);

// Postavljanje WiFi u klijentski način rada
esp8266.println("AT+CWMODE=1");
delay(400);

// Spajanje na Wifi
esp8266.println("AT+CWJAP=\"" + AP + "\",\"" + PASS + "\"");

}

// Struktura mjerenja
typedef struct measurement {
    char status;
    unsigned long timestamp;
} Measurement;

Measurement data[2][DATA_POINTS];
Measurement current;

// Očitavanje senzora
int REED[2][3] = {
    { HIGH, HIGH, HIGH },
    { HIGH, HIGH, HIGH }
};

int REED_STATE[2] = { LOW, LOW };

short index[2] = { 0, 0 };

void loop() {
    take_measurements();
    upload_data();
}

void take_measurements() {

    Serial.println("Taking measurements");

    // Svaki zadani interval napravi novo mjerenje
    for(short i = 0; i < UPLOAD_INTERVAL * RESOLUTION; i++) {
        unsigned long now = millis();
```

```
int current_0 = digitalRead(REED_0_PIN);
int current_1 = digitalRead(REED_1_PIN);

REED[0][0] = REED[0][1];
REED[0][1] = REED[0][2];
REED[0][2] = current_0;

REED[1][0] = REED[1][1];
REED[1][1] = REED[1][2];
REED[1][2] = current_1;

if (REED[0][0] == REED[0][1] && REED[0][1] == REED[0][2] && REED_STATE[0]
!= current_0) {

    current.status = (current_0 == HIGH) ? 'l' : 'h';
    current.timestamp = now;
    data[0][index[0]] = current;
    index[0]++;

    REED_STATE[0] = current_0;

    Serial.println("REED1: " + String(current.status));
}

if (REED[1][0] == REED[1][1] && REED[1][1] == REED[1][2] && REED_STATE[1]
!= current_1) {

    current.status = (current_1 == HIGH) ? 'l' : 'h';
    current.timestamp = now;
    data[1][index[1]] = current;
    index[1]++;

    REED_STATE[1] = current_1;

    //Serial.println("REED2: " + String(current.status));
}

// Ako smo popunili memoriju, prekidamo postupak da ne izgubimo podatke
if (index[0] == DATA_POINTS || index[1] == DATA_POINTS) {
    // Serial.println("Popunjena memorija");
    break;
}

delay(SLEEP_INTERVAL);
}
```



```
}

void upload_data() {
    Serial.println("UPLOADING -----");

    String req = String("POST /data HTTP/1.1\r\nHost: logging.logevent.net\r\nContent-
Length: ");
    String body = String("R1:");

    for (short i = 0; i < index[0]; i++) {
        body += String(data[0][i].status) + String(data[0][i].timestamp / 100) + ",";
    }

    body += String("\n");
    body += String("R2:");

    for (short i = 0; i < index[1]; i++) {
        body += String(data[1][i].status) + String(data[1][i].timestamp / 100) + ",";
    }

    req += String(body.length()) + "\r\n\r\n" + body;

    Serial.println(req);

    index[0] = 0;
    index[1] = 0;

    // Slanje na server
    esp8266.println("AT+CIPSTART=\"TCP\", \"logging.logevent.net\",80");
    delay(500);
    esp8266.println("AT+CIPSEND=" + String(req.length() + 2));
    delay(200);
    esp8266.println(req);

    Serial.println("DONE -----");
}
```

## **9. ZAKLJUČAK**

Svijet je prošao kroz tri industrijske revolucije. Treća je bila najopsežnija, no četvrta, koja tek nadolazi, je nemjerljiva s prethodnima. Pruža mnoge prednosti za one koji su spremni adaptirati se novim postulatima rada, dok je mana za one inertne i trome.

Ljude je teško natjerati na promjenu, posebno ako nisu svjesni što ta promjena znači. Lean i digitalna transformacija zvuči komplicirano i apstraktno na prvu, no primjenjivši brze i jednostavne simulacije moguće je sudionicima demonstrirati što ih čeka. Lean igre i simulacije trebale bi se što više koristiti kao uvod u kompletnu transformaciju kompanije.

Pokazalo se i na primjerima da ljudi lakše prihvataju nešto kada znaju što to nešto donosi.

Industija 4.0 obuhvaća mnoge tehnologije koje su još uvijek u ranoj fazi prihvatanja. Već sada se vide rezultati među onima najnaprednijima. Svako poduzeće koje želi ostati konkurentno morati će proći kroz vitku i digitalnu transformaciju. Dualna transformacija predstavlja recept kako je provesti. U ovom radu, primijenio sam jedan lean i digitalni alat. Lean je bio Kaizen, dok sam kao digitalni alat proveo digitalizaciju tokarilice kroz njezino umrežavanje na internet i kreiranje IoT. Pokazali smo na jednostavnom primjeru kakve benefite donosi Industrija 4.0.

## 10. LITERATURA

1. <https://www.newcastlesys.com/blog/bid/337009/lean-manufacturing-quotes-for-education-and-inspiration>
2. <http://slideplayer.com/slide/6395162/> Herold, Z.: Računalna i inženjerska grafika, Zagreb, 2003.
3. <http://www.leansimulations.org/2010/11/penny-game.html>
4. [https://www.mckinsey.com/~media/mckinsey/dotcom/client\\_service/financial%20services/latest%20thinking/reports/lean\\_management\\_new\\_frontiers\\_for\\_financial\\_institutions.ashx](https://www.mckinsey.com/~media/mckinsey/dotcom/client_service/financial%20services/latest%20thinking/reports/lean_management_new_frontiers_for_financial_institutions.ashx)
5. <https://www.britannica.com/event/Industrial-Revolution>
6. <https://www.epa.gov/lean/lean-thinking-and-methods-kaizen>
7. <https://www.simplypsychology.org/compliance.html>
8. [https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=0ahUKUwjyz7Da9c\\_aAhUS3aQKHeRQDo4QFggpMAA&url=http%3A%2F%2Fwww.apeiron-uni.eu%2Fflycboardclient%2FDetail.aspx%3FDocumentID%3D20923&usg=AOvVaw19VLn6uOtQfhF6zgyEB-ja](https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=0ahUKUwjyz7Da9c_aAhUS3aQKHeRQDo4QFggpMAA&url=http%3A%2F%2Fwww.apeiron-uni.eu%2Fflycboardclient%2FDetail.aspx%3FDocumentID%3D20923&usg=AOvVaw19VLn6uOtQfhF6zgyEB-ja)
9. <https://www.leanagiletraining.com/better-agile/agile-penny-game-rules/>
10. <http://www.leansimulations.org/2015/01/story-telling-facilitating-teams-and.html>
11. [https://mn.gov/admin/assets/white\\_albatross\\_facilitation\\_exercise\\_tcm36-68780.pdf](https://mn.gov/admin/assets/white_albatross_facilitation_exercise_tcm36-68780.pdf)
12. Matejak, N.: Industrija 4.0 – Sadašnjost ili budućnost u Hrvatskoj, diplomski rad, Sveučilište Sjever, Varaždin, 2017.
13. [www.hgk.hr](http://www.hgk.hr)
14. <https://www.vrs.org.uk/virtual-reality/what-is-virtual-reality.html>
15. <http://www.realitytechnologies.com/augmented-reality>
16. <https://pssjournal.biomedcentral.com/articles/10.1186/1754-9493-2-16>
17. <https://www.explainthatstuff.com/virtualreality.html>
18. Ivica Veža: "Hrvatska industrija na putu prema Industriji 4.0", 2016
19. <https://ec.europa.eu/digital-single-market/en/desi>
20. <https://lider.media/aktualno/biznis-i-politika/hrvatska/desi-hrvatska-medu-najlosijima-u-eu-po-digitalnoj-konkurentnosti/>
21. <https://lider.media/konferencijske-vijesti/vlacic-novi-ministar-gospodarstva-morao-bi-implementirati-elemente-industrije-4-0/>

22. <http://www.poslovni.hr/hrvatska/bazu-industrije-cini-tocno-591-tvrtka-334075>
23. [https://en.wikipedia.org/wiki/Fourth\\_Industrial\\_Revolution](https://en.wikipedia.org/wiki/Fourth_Industrial_Revolution)
24. [http://www.europarl.europa.eu/RegData/etudes/STUD/2016/570007/IPOL\\_STU\(2016\)570007\\_EN.pdf](http://www.europarl.europa.eu/RegData/etudes/STUD/2016/570007/IPOL_STU(2016)570007_EN.pdf)
25. <https://www.bcg.com/capabilities/operations/embracing-industry-4.0-rediscovering-growth.aspx>
26. <http://bigdata-madesimple.com/big-datas-role-fourth-industrial-revolution/>
27. [https://www.i-scoop.eu/industry-4-0/#Industry\\_40\\_building\\_blocks\\_the\\_Industrial\\_Internet\\_of\\_Things](https://www.i-scoop.eu/industry-4-0/#Industry_40_building_blocks_the_Industrial_Internet_of_Things)
28. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=LEGISSUM:si0009>
29. <https://www.i-scoop.eu/internet-of-things-guide/internet-of-things-in-manufacturing/>
30. <https://www2.deloitte.com/insights/us/en/focus/industry-4-0/cybersecurity-managing-risk-in-age-of-connected-production.html>
31. [https://www.i-scoop.eu/cloud-computing/#What\\_is\\_cloud\\_computing](https://www.i-scoop.eu/cloud-computing/#What_is_cloud_computing)
32. Ugur M Dilberoglu, Bahar Gharehpapagh, Ulas Yaman, Melik Dolen: "The role of additive manufacturing in the era of Industry 4.0"
33. <https://www.bcg.com/publications/2013/technology-digital-innovation-3d-printing-will-change-game.aspx>
34. <https://www.popularmechanics.com/technology/a19287/steel-bike-frame-3d-printed-with-a-robotic-welding-arm/>
35. <https://www.arch2o.com/shoes-with-mid-sole-3d-printed-from-recycled-ocean-waste-adidas-and-parley-for-the-oceans/>
36. <https://atos.net/en/blog/industry-4-0-3d-printing-manufacturing-industries>
37. <http://www.3dfarma.hr/usluge/3d-print>
38. <https://www.3dhubs.com/knowledge-base/additive-manufacturing-process>
39. [https://www.globalspec.com/ImageRepository/LearnMore/20135/Autodesk\\_moldflow2011\\_features\\_cad\\_interop\\_tools\\_large\\_1141x823b3aceea3dd5cf469b84e8ae3e4968af3d.png](https://www.globalspec.com/ImageRepository/LearnMore/20135/Autodesk_moldflow2011_features_cad_interop_tools_large_1141x823b3aceea3dd5cf469b84e8ae3e4968af3d.png)
40. [https://en.wikipedia.org/wiki/Artificial\\_intelligence](https://en.wikipedia.org/wiki/Artificial_intelligence)
41. <https://www.mckinsey.com/~media/McKinsey/Industries/Advanced%20Electronics/Our%20Insights/How%20artificial%20intelligence%20can%20deliver%20real%20value%20to%20companies/MGI-Artificial-Intelligence-Discussion-paper.ashx>
42. Smartening up with artificial intelligence (AI): What's in it for Germany and its industrial sector? McKinsey & Company, April 2017

43. <http://static1.uk.businessinsider.com/image/56296878dd0895594b8b4608-2514-1886/461841934.jpg>
44. <https://arc-anglerfish-arc2-prod-spectator.s3.amazonaws.com/public/DX4TP2F7ZRHEFG5GT7UTRKZ5DQ>
45. [https://cdn-images-1.medium.com/max/1280/1\\*B3WkgNm4luAjKJRnXfTxg.jpeg](https://cdn-images-1.medium.com/max/1280/1*B3WkgNm4luAjKJRnXfTxg.jpeg)
46. [http://new.ieiworld.com/\\_attach\\_file/filehub/223.gif](http://new.ieiworld.com/_attach_file/filehub/223.gif)
47. <https://a0.muscache.com/airbnb/static/logos/belo-200x200-4d851c5b28f61931bf1df28dd15e60ef.png>
48. <http://www.tvistra.hr/wp-content/uploads/2018/05/Uber-e1525976605554.jpg>
49. <https://www.cnbc.com/2018/05/22/the-airbnb-effect-fueling-start-up-ecosystems-around-the-world.html>
50. <https://www.guestready.com/og.png>
51. [https://cdn.static-economist.com/sites/default/files/images/print-edition/20180310\\_USP003\\_0.jpg](https://cdn.static-economist.com/sites/default/files/images/print-edition/20180310_USP003_0.jpg)
52. James P. Womack, Daniel T. Jones: Lean Thinking: Banish Waste and Create Wealth in Your Corporation, Revised and Updated
53. <http://leanmanufacturingtools.org/192/what-is-5s-seiri-seiton-seiso-seiketsu-shitsuke/>
54. <https://www.5stoday.com/content/images/custom/5s-before-after-illustration.jpg?v=2>
55. <http://leanmanufacturingtools.org/549/vsm-value-stream-mapping/>
56. <https://image.slidesharecdn.com/valuestreammappingfornon-manufacturing-martin-replacement-100706084816-phpapp01/95/value-stream-mapping-for-non-manufacturing-environments-41-728.jpg?cb=1278406373>
57. <https://www.hgk.hr/documents/leandigitalnatanformacijanedeljko-stefanic-20185aec184cac6b3.pdf>
58. [http://strojevi.grf.unizg.hr/media/Odabrana%20poglavlja%20upravljanja%20kvalitetom/Sest%20sigma%202011\\_12.pdf](http://strojevi.grf.unizg.hr/media/Odabrana%20poglavlja%20upravljanja%20kvalitetom/Sest%20sigma%202011_12.pdf)
59. <http://www.feroimpex.hr>
60. <http://www.poslovni.hr/hrvatska/hamag-sa-115-milijuna-kuna-jamci-za-ulaganje-feroimpexa-tesko-31-mil-kuna-258148>
61. <https://lider.media/aktualno/krenuo-projekt-hrvatskih-inovativnih-rjesenja-za-globalnu-auto-industriju-vrijedan-54-milijuna-kuna/>
62. [http://repozitorij.fsb.hr/3931/1/Kaizen\\_Workshop\\_as\\_an\\_Important\\_Element.pdf](http://repozitorij.fsb.hr/3931/1/Kaizen_Workshop_as_an_Important_Element.pdf)
63. [https://cdn.itead.cc/media/catalog/product/i/m/im131122016\\_6.jpg](https://cdn.itead.cc/media/catalog/product/i/m/im131122016_6.jpg)
64. <https://cdn3.volusion.com/btfzd.umflq/v/vspfiles/photos/184-3.jpg?1423438804>

65. <https://cdn.sparkfun.com/assets/f/4/e/2/7/51eeb8f9ce395f0778000000.png>
66. <https://d2n4wb9orp1vta.cloudfront.net/cms/brand/PM/2018-PM/PM0218-P-Doosan-Puma-2600.jpg;quality=90;width=560>
67. [https://cdn-images-1.medium.com/max/1200/1\\*9ZSqkf-cT6NdQbj0I30l6g.jpeg](https://cdn-images-1.medium.com/max/1200/1*9ZSqkf-cT6NdQbj0I30l6g.jpeg)
68. [https://cdn-images-1.medium.com/max/1600/1\\*sxA4dxPaJEr8julLO494kA.png](https://cdn-images-1.medium.com/max/1600/1*sxA4dxPaJEr8julLO494kA.png)
69. <https://medium.com/@cgrant/using-the-esp8266-wifi-module-with-arduino-uno-publishing-to-thingspeak-99fc77122e82>
70. <https://cdn.sparkfun.com/assets/0/2/0/4/e/51eed447ce395f924b000000.png>
71. <https://cdn.sparkfun.com/r/400-400/assets/b/2/e/d/6/51eebc54ce395fc078000001.png>
72. <https://cdn.sparkfun.com/datasheets/Dev/Arduino/Boards/Arduino-Pro-Mini-v14.pdf>